

SVEUČILIŠTE JURJA DOBRILE U PULI
FAKULTET EKONOMIJE I TURIZAMA „DR. MIJO MIRKOVIĆ“

BARBARA OLANOVIĆ

**„NOMINALNE I REALNE BRUTO PLAĆE, ZAPOSLENOST I INFLACIJA U RH –
MEĐUSOBNI UTJECAJ ODABRANIH VARIJABLI“**

PULA, 2018.

SVEUČILIŠTE JURJA DOBRILE U PULI
FAKULTET EKONOMIJE I TURIZAMA „DR. MIJO MIRKOVIĆ“

DIPLOMSKI STUDIJ

BARBARA OLANOVIĆ

**„NOMINALNE I REALNE BRUTO PLAĆE, ZAPOSLENOST I INFLACIJA U RH –
MEĐUSOBNI UTJECAJ ODABRANIH VARIJABLI“**

Diplomski rad

JMBAG: 0303037324, redoviti student

Smjer: Ekonomija

E-mail: bolanovic@unipu.hr

Br. Indeksa: 749-ED

Kolegij: Makroekonomski management

Mentor: Doc.dr.sc. Daniel Tomić

Pula, srpanj 2018.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisana BARBARA OLANOVIĆ, kandidat za magistra ekonomije ovime izjavljujem da je ovaj Diplomski rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

U Puli, _____, 2018. godine



IZJAVA

o korištenju autorskog djela

Ja, BARBARA OLANOVIĆ dajem odobrenje Sveučilištu Jurja Dobrileu Puli, kao nositelju prava iskorištavanja, da moj diplomski rad pod nazivom „NOMINALNE I REALNE BRUTO PLAĆE, ZAPOSLENOST I INFLACIJA U RH – MEĐUSOBNI UTJECAJ ODABRANIH VARIJABLI“ koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, _____

Potpis

SADRŽAJ

1. UVOD	1
2. ZAPOSLENOST I NEZAPOSLENOST U HRVATSKOJ.....	4
3. BRUTO I NETO PLAĆE U HRVATSKOJ	12
4. INFLACIJA U HRVATSKOJ.....	21
5. PHILLIPSOVA KRIVULJA I OKUNOV ZAKON	28
5.1. Phillipsova krivulja	28
5.2. Okunov zakon	32
6. METODOLOŠKI PRISTUP ODABRANIH VARIJABLI.....	35
6.1. Kretanje odabranih varijabli	36
6.2. Odabir modela za analizu rezultata	40
6.3. Ocjena kvalitete modela	41
6.4. Testiranje utjecaja odabranih varijabli	44
6.4.1. Prikaz utjecaja varijabli kroz 30 godina	44
6.4.2. Grangerova uzročnost između odabranih varijabli	46
6.4.3. Doprinos varijabli na prognostičku grešku kroz 30 kvartala	47
7. ZAKLJUČAK I KRITIČKI OSVRT	51
LITERATURA	54
POPIS GRAFIKONA	57
POPIS TABLICA.....	58
POPIS SLIKA	59
PRILOG	60
SAŽETAK	68

1. UVOD

Gospodarski napredak je oduvijek bio jedna od najzastupljenijih tema u svim znanstvenim, političkim te svakodnevnim pitanjima života svakoga čovjeka. Osnovni indikator gospodarskog rasta je povećanje dohotka koji se u pravilu mjeri pomoću bruto domaćeg proizvoda (BDP) te bruto domaćeg proizvoda po stanovniku (BDP percapita).¹ Bruto domaći proizvod je zbroj dodanih vrijednosti proizvedenih od svih proizvođača i stanovnika u domaćem gospodarstvu, kojem se doda vrijednost poreza umanjenoj za subvencije. Dodana vrijednost jednaka je vrijednosti outputa umanjenoj za vrijednost roba i usluga potrebnih za proizvodnju toga outputa. Za mjerenje BDP-a analitičari koriste tri standardna pristupa, a to su proizvodni koji prikazuje račun proizvodnje, dohodovni koji iskazuje račun dohotka, te troškovni koji preuređuje račun roba i usluga.² Gospodarski rast uključuje ekonomske te društvene procese strukturnih promjena i gospodarskog razvoja. Upravo gospodarski rast može se razmatrati sa različitih gledišta. Unutar gospodarskog rasta, u ovome radu će se analizirati četiri varijable koje su također značajne za cjelokupan gospodarski rast ali i za gospodarski razvoj određene zemlje, u ovome slučaju Hrvatske. Isto tako, odnos bruto domaćeg proizvoda u stvaranju veće stope zaposlenosti i pada stope nezaposlenosti je vrlo značajan te je cilj svakog gospodarstva doseći što viši gospodarski rast, veći gospodarski rast i što nižu stopu nezaposlenosti, pri tome ne stvarajući inflatorne pritiske. Za razvoj i rast svake zemlje pa tako i Hrvatske vrlo je važno pratiti kretanja zaposlenosti i nezaposlenosti. Isto tako, važno je održavati stabilnu inflaciju iako Hrvatska ne bilježi značajne šokove inflacije u dugom roku. Osim navedenog, plaće su u Hrvatskoj posljednjih godina tema o kojoj se puno priča, ali ukazuju i na značajnu problematiku. Istina je da se Hrvatska počela oporavljati od gospodarske krize, sporo ali (relativno) sigurno. Otkako je Hrvatska počela izlaziti iz gospodarske recesije, plaće su tijekom nekoliko godina realno porasle oko 5%, prema podacima Državnog zavoda za statistiku. Međutim, problem je u tome što velika većina zaposlenih u Hrvatskoj prima ispodprosječne plaće, a može se reći čak i minimalne. Za rast i razvoj svakog gospodarstva značajne su još mnogobrojne

¹S.Sharma, D.Tomić, *Ekonomika politika i makroekonomski management*, Mikrorad, Zagreb, 2012., str. 90

²Ibidem, str. 27

pojave koje se javljaju ali za potrebe ovoga rada analizirane su plaće, zaposlenost, odnosno nezaposlenost te inflacija.

Rad se sastoji od dva dijela. U prvom dijelu prikazan je teorijski pristup odabranih varijabli – plaće, zaposlenost i inflacija u Hrvatskoj. Drugi dio je metodološki dio u kojem se empirijski istraživalo kako odabrane varijable međusobno utječu jedna na drugu. Varijable koje će se analizirati u radu su realne i nominalne bruto plaće, broj zaposlenih te indeks temeljne inflacije. Istraživanje se temelji na procjeni regresijskog modela pomoću ekonometrijskog programa Gretl. U radu su korištene metode analize i sinteze, induktivno-deduktivna metoda, metoda klasifikacije, generalizacije, komparativna metoda, metoda apstrakcije, deduktivna i statističke metoda, metoda deskripcije, kompilacije te ekonometrijska metoda.

U poglavlju ZAPOSLENOST I NEZAPOSLENOST U HRVATSKOJ teoretski su objašnjeni pojmovi zaposlenosti i nezaposlenosti. Isto tako, analizirani su statistički podaci, odnosno kretanja zaposlenosti u Hrvatskoj. Također, navedeni su i potencijalni uzroci nezaposlenosti, analizirano doseljeno i odseljeno stanovništvo u inozemstvo te stajališta nekoliko ekonomista o zaposlenosti, odnosno problemu nezaposlenosti. Sljedeće poglavlje, odnosno poglavlje pod nazivom BRUTO I NETO PLAĆE U HRVATSKOJ objašnjava razlike između nominalnih i realnih plaća, analizirane su prosječne mjesečne bruto plaće te prosječne mjesečne neto plaće u Hrvatskoj. Isto tako, unutar navedenog poglavlja govori se o minimalnim plaćama u Hrvatskoj te o usporedbi sa EU. Osim toga, poglavlje govori o troškovima rada te o razlikama između plaća unutar različitih sektora. Poglavlje INFLACIJA U HRVATSKOJ govori o stanju u Hrvatskoj glede inflacije. Također, objašnjen je sam pojam, odnosno definicija inflacije te navedeni njezini uzroci. Isto tako, navedena su razna stajališta i mišljenja nekoliko ekonomista. Teoretski dio inflacije obuhvaća širi dio navedene teme iako je u metodološkom dijelu obuhvaćena samo temeljna inflacija. Razlog tomu je što temeljna inflacija izostavlja promjene cijene energenata i hrane. Realno gledajući, te dvije stavke u prosjeku imaju najveće promjene u kratkom roku. Poglavlje koje slijedi je PHILLIPSOVA KRIVULJA I OKUNOV ZAKON koje objašnjava navedena dva fenomena. Phillipsova krivulja i Okunov zakon usko su povezani s temom koja se obrađuje unutar ovoga rada. Phillipsova krivulja

predstavlja odnos između nezaposlenosti i inflacije, a Okunov zakon objašnjava odnos između nezaposlenosti i BDP-a. Okunov zakon, samo je dio empirijske makroekonomije koje zajedno sa svim vezanim tematikama kao što je Phillipsova krivulja pruža mogućnost dati jasne odgovore za potencijalne probleme u hrvatskom gospodarstvu. Phillipsova krivulja i Okunov zakon su od značajnih fenomena za proučavanje svakog gospodarstva. Sljedeće poglavlje je poglavlje u kojemu je prikazan metodološki pristup odabranih varijabli – nominalne i realne bruto plaće, broj zaposlenih i indeks temeljne inflacije. Unutar tog poglavlja prikazano je kretanje odabranih varijabli, zatim odabir odgovarajućeg modela za analizu te ocjena kvalitete modela. Isto tako, testiran je međusobni utjecaj odabranih varijabli. Testiran je utjecaj kroz 30 kvartala, preko Grangerove uzročnosti te doprinosa varijabli na prognostičku grešku kroz 30 kvartala. Na kraju rada je zaključak i kritički osvrt autora rada.

Cilj ovoga rada je prikazati stanje u Hrvatskoj glede zaposlenosti odnosno nezaposlenosti, stanje bruto i neto plaća, prikazati samu problematiku plaća te analizirati jednu od kompleksnijih pojava unutar svakog gospodarstva a to je inflacija. Svrha rada je također ukazati na problematiku te osim toga, analizirati međusoban utjecaj navedenih varijabli. Varijable koje su u metodološkom dijelu analizirane odabrane su iz razloga što predstavljaju jedne od najvažnijih parametara za promatranje svakog gospodarstva pa tako i Hrvatske. Broj zaposlenih za analizu je odabran zbog toga što upravo rast ili pad zaposlenih je vrlo važan parametar, u nekim sferama čak i važniji od nezaposlenosti. To znači da analize o nezaposlenosti treba uzimati i koristiti s rezervom jer je, analizirajući trenutno stanje u Hrvatskoj, pad upravo tog pokazatelja najvećim dijelom uzrokovan odlaskom radno aktivnog stanovništva u inozemstvo. Realne i nominalne bruto plaće se analiziraju iz razloga što upravo bruto plaće prikazuju stvarno stanje isplaćenih plaća. Drugim riječima, zaposlenici kojima se plaće isplaćuju, u većini slučajeva imaju uvid u neto plaće te vrlo često ne uzimaju u obzir koliko je zapravo njihov poslodavac platio njihov rad koji se očituje u bruto iznosima. Varijabla temeljne inflacije odabrana je iz razloga što isključuje, kako je već gore navedeno, promjene cijena energenata i prehrambenih proizvoda. Drugim riječima, svrha usmjerivanja na temeljnu inflaciju je da se iz inflacije isključe nemonetarne determinante inflacije.

2. ZAPOSLENOST I NEZAPOSLENOST U HRVATSKOJ

Tržište čini ponuda rada i potražnja za radom. Ponuda rada definira se kao broj radnika koji je raspoloživ za zapošljavanje za određeno radno mjesto i ovisi o stanju i uvjetima na tržištu rada. Može se zaključiti da je svaka ponuda rada specifična za sebe te je stvorila svoje tržište. Tržišta ponude rada se razlikuju prema određenim vještinama, razinama znanja i obrazovanja, stručnim kvalifikacijama i prema tome su sami stvorili uvjete za zapošljavanje.³ S druge strane, potražnja za radom uobičajeno se promatra na razini poduzeća i određena je ekonomskim uvjetima, tehnologijom, kapitalom i razinom nadnica. Potražnja za radom izvedena je iz potražnje za proizvodom. Poslodavac upošljava rad uzimajući u obzir koliko će rad doprinijeti proizvodnji nekog dobra za prodaju. Stoga ne čudi što je potražnja za radom, s jedne strane u funkciji tržišta proizvoda, a s druge strane u funkciji cijene rada i same cijene ostalih proizvodnih čimbenika.⁴

Statistika rada se izvodi iz podataka o tržištu rada koji se prikupljaju iz različitih izvora. Na najopćenitijoj razini ona se temelji na podacima o ponudi radne snage (zaposlenost i nezaposlenost), s jedne strane, i potražnji za radom (slobodnim radnim mjestima), s druge strane. Djelotvorna statistika rada i sustavi informiranja počinju s identifikacijom potencijalnih korisnika podataka (poslodavaca, radnika i njihovih predstavnika, tražitelja zaposlenja, kreatora politike, rukovoditelja i istraživača). Kakve i koliko podataka o tržištu rada svaki od navedenih korisnika traži, ovisi o stupnju gospodarskog razvoja neke zemlje i složenosti njenoga gospodarstva.⁵

Ukupan broj zaposlenog stanovništva determiniran je ukupnim brojem stanovnika neke zemlje, njegovom ekonomskom strukturom te dobnom i spolnom strukturom. Ukupan broj stanovnika Republike Hrvatske smanjen je za 3,4% uspoređujući popise stanovništva 2001. godine i 2011. godine. Prema popisu iz 2001. godine zabilježeno je 4.437.460 stanovnika, a prema popisu iz 2011. godine zabilježeno je 4.284.460

³M.Bušelić, *Tržište rada: teorijski pristup*, Sveučilište Jurja Dobrile, Fakultet za ekonomiju i turizam „Dr. Mijo Mirković“, Pula, 2014., str. 16

⁴Ibidem., str. 27.

⁵N.Kerovec, *Kako mjeriti nezaposlenost*, Pregledni članak, Hrvatski zavod za zapošljavanje, Zagreb, 1999., dostupno na: <https://hrcak.srce.hr/file/47273>

stanovnika što ukazuje da je prema zadnjem popisu stanovništva 2011. godine smanjen broj za 152.571, odnosno gore navedenih 3,4%. Takav nepovoljan trend kretanja stanovništva uz postojeću društveno-ekonomsku situaciju nepovoljno se odrazio na strukturu ukupnog broja zaposlenih prema gospodarskim subjektima (pravni subjekti, obrt i slobodne profesije te individualni poljoprivrednici).⁶

U nastavku (Tablica 1.) prikazan je prosječan broj zaposlenih i nezaposlenih osoba u u Hrvatskoj od 1999. godine do 2016. godine.

Tablica 1. *Zaposleni i nezaposleni u Hrvatskoj od 1999. do 2016. godine*

GODINA	ZAPOSLENI u 000	NEZAPOSLENI
1999.	1.364	321.866
2000.	1.341	357.872
2001.	1.348	380.195
2002.	1.359	389.741
2003.	1.393	329.799
2004.	1.409	309.875
2005.	1.420	308.738
2006.	1.468	291.616
2007.	1.517	264.448
2008.	1.555	236.741
2009.	1.499	270.557
2010.	1.432	289.234
2011.	1.411	313.988
2012.	1.395	324.324
2013.	1.364	345.112
2014.	1.342	328.187
2015.	1.357	285.906
2016.	1.390	241.860

Izvor: Državni zavod za statistiku, Statistički ljetopis (2006., 2007., 2012., 2017.)

Prema podacima iz tablice može se zaključiti da je broj zaposlenih u Hrvatskoj od 2000. godine do 2008. godine imao tendenciju rasta. Nakon gospodarske krize koja se pojavila u 2008. godini bilježi se pad zaposlenih osoba. Promatrajući isto razdoblje do gospodarske krize, zaposlenost je godišnje rasla u prosjeku 1,83%. Najveći porast zaposlenih bilježi se u 2006. godini u odnosu na 2005. godinu gdje je zaposlenost porasla za 3,27%. Nakon 2008. godine broj zaposlenih u Hrvatskoj bilježi pad.

⁶I. Kelebuš, *Zaposlenost i nezaposlenost u Hrvatskoj i EU*, dostupno na: [http://www.poslovni-info.eu/sadrzaj/gospodarstvo-rh/zaposlenost-i-nezaposlenost-u-hrvatskoj-i-eu-\(1\)/](http://www.poslovni-info.eu/sadrzaj/gospodarstvo-rh/zaposlenost-i-nezaposlenost-u-hrvatskoj-i-eu-(1)/)

Najveći pad bilježi se u 2010. godini kada je zaposlenost pala za 4,47% u odnosu na prethodnu 2009. godinu. Promatrajući godine od 2008. do 2015. zaposlenost je pala u prosjeku za 2,23% godišnje.

Padom broja zaposlenih u Hrvatskoj sve je više vidljiv porast broja nezaposlenih što posljednjih godina predstavlja veliki problem u Hrvatskoj. Nezaposlenost se definira kao društvena pojava ili stanje u kojemu se dio radno sposobnog stanovništva ne može zaposliti primjereno vlastitim sposobnostima i kvalifikacijama uz određenu zaradu. U Hrvatskoj postoje dva izvora podataka o kretanju zaposlenosti i nezaposlenosti. Prvi pokazatelj je administrativna nezaposlenost, odnosno administrativni izvori. Oni prikazuju evidenciju nezaposlenih koji su prijavljeni Hrvatskom zavodu za zapošljavanje (HZZ). Drugi pokazatelji su oni iz ankete radne snage (ARS) koju od 1996. godine provodi Državni zavod za statistiku (DZS), a čija je metodologija usklađena s pravilima i uputama Međunarodne organizacije rada (MOR) te Europskog ureda za statistiku (Eurostat), čime se osigurava metodološka usporedivost s istraživanjima u zemljama Europske Unije. Razlika je u tome što se prema pravilima MOR-a nezaposlenom osobom smatra osoba između 15. godine i 74. godine života koja je bez posla, ali je u proteklih mjesec dana aktivno tražila posao i sposobna je raditi tijekom sljedeća dva tjedna. Osoba koja nije aktivno tražila posao, a prijavljena je u HZZ-u, nezaposlena je prema administrativnom izvoru, ali nije nezaposlena prema MOR-u.⁷

Prema podacima iz Tablice 1. vidljivo je da broj nezaposlenih od 1999. godine raste sve do 2002. godine nakon čega se bilježi pad broja nezaposlenih. Najveći pad broja nezaposlenih u razdoblju od 2002. godine do 2008. godine je bilo 2003. godine kada je broj zaposlenih pao za 15,38%. Nakon što je naslijedila gospodarska kriza, broj zaposlenih opet počinje rasti te je u 2009. godini zabilježen najveći rast broja nezaposlenih za 12,50% u odnosu na prethodnu 2008. godinu. Nakon 2013. godine broj nezaposlenih opet počinje rasti u prosjeku za 11,06%.

⁷P.Bejaković, *Nezaposlenost i zaposlenost*, dostupno na: <http://www.ijf.hr/rosen/rosenic/zaposlenost.pdf>

Glavni uzroci nezaposlenosti su:⁸

- depresije u gospodarstvu
- promjene u potražnji za određenom vrstom radnika
- sezonske promjene
- tehnološke promjene
- osobno nesnalaženje
- promjene u ponašanju ljudi
- promjene potreba ljudi
- promjene želja ljudi

Uzroci nezaposlenosti mogu biti mnogobrojni, ali se smatra da je glavni uzrok nezaposlenosti nedostatak radnih mjesta na kojima bi se pojedinci koji su radno sposobni mogli zaposliti, što samim time ima mikro i makro implikativan učinak. Škare (2010.) naglašava da uzroke rasta nezaposlenosti treba pronalaziti u institucionalnim i ostalim strukturnim promjenama na tržištu rada. U ekonomskim analizama ovog fenomena se naglašava i visina standardne nadnice kao jedan od glavnih uzroka nezaposlenosti. Isto tako, problematika je i u fleksibilnosti nadnica te problematika selekcije radnika i otpuštanja.⁹ Kada ustupi značajan porast nezaposlenosti važno je suzbijanje nezaposlenosti koja se postiže aktivnim i pasivnim mjerama na tržištu rada. Aktivne mjere potiču potražnju za radom, a to se ostvaruje putem različitih programa za otvaranje novih radnih mjesta, prekvalifikacijom, stručnim osposobljavanjem radnika i slično. Kao krajnji ishod tih mjera očekuje se povećana proizvodnja, ali i porast kupovne moći građana te povećana potražnja za robom i uslugama. S druge strane, pasivne mjere zasnivaju se na pružanju socijalne i materijalne pomoći nezaposlenima, odnosno, njima se na različite načine pokušava smanjiti ponuda radne snage. Pasivne mjere su kratkoročne, zahtijevaju financijsku podršku od strane države i ne predstavljaju trajno rješenje pa ih se općenito smatra manje prihvatljivima.¹⁰

U proteklih nekoliko godina u Hrvatskoj se sve više govori o povećanju stope zaposlenosti. Dolazi do pitanja - kako raste zaposlenost, a nezaposlenost je veliki

⁸M.Bušelić, Op.cit., str. 93.-94.

⁹S.Sharma, D.Tomić, op.cit., str.94

¹⁰M.Bušelić, op.cit., str. 98.

problem u Hrvatskoj. Uspoređujući s Europskom unijom, sve zemlje članice Europske unije bilježe gospodarski rast koji povećava stopu zaposlenosti i smanjuje nezaposlenost, a Hrvatska je u trećem tromjesečju 2017. godine imala najveći rast stope zaposlenosti za 1,4% u odnosu na prethodno tromjesečje, pokazalo je izvješće o zapošljavanju i socijalnim kretanjima u Europskoj uniji.¹¹ S druge strane, stopa nezaposlenosti u Europskoj uniji u prosincu 2017. godine ostala je nepromijenjena na mjesečnoj razini, a Hrvatska bilježi daljnji pad i ponovno je izdvojena u skupinu zemalja s najvećim padom stope nezaposlenosti na godišnjoj razini, koje također pokazuje najnovije izvješće Eurostata.¹²

U Hrvatskoj dolazi do problema iseljavanja stanovništva što direktno u statistici, odlaskom radno sposobnog stanovništva, povećava stopu zaposlenosti a smanjuje nezaposlenost. Drugim riječima, Hrvatska se suočava sa problemom nedostatka radne snage što je iz godine u godinu sve veći problem. Statistika ponekad ne daje potpunu sliku stanja nekoga gospodarstva. U ovome slučaju ne uzima se u obzir odlazak radne snage pa statistika pokazuje da se u Hrvatskoj bilježi značajan pad stope nezaposlenosti, što u realnom svijetu to ipak nije tako. Nadalje, u nastavku, prema podacima Državnog zavoda za statistiku, prikazano je doseljeno i odseljeno stanovništvo u Republici Hrvatskoj prema dostupnim podacima (Tablica 2. i 3.).

Tablica 2. *Doseljeno stanovništvo iz inozemstva u RH od 2011. do 2016. godine*

Prostorna jedinica	Godina	Doseljeni iz inozemstva
REPUBLIKA HRVATSKA	2011	8.534
REPUBLIKA HRVATSKA	2012	8.959
REPUBLIKA HRVATSKA	2013	10.378
REPUBLIKA HRVATSKA	2014	10.638
REPUBLIKA HRVATSKA	2015	11.706
REPUBLIKA HRVATSKA	2016	13.985

Izvor: Izrada autora prema podacima Državnog zavoda za statistiku

Analizirajući podatke doseljenika u Republiku Hrvatsku od 2011. godine do 2016. godine može se zaključiti da se radi o porastu doseljenog stanovništva. U promatranom razdoblju zabilježeno je u prosjeku 10.700 doseljenog stanovništva. U

¹¹ Lider, *Eurostat: Stopa nezaposlenosti u EU stagnira, u Hrvatskoj opada*, 2018., dostupno na:

<https://lider.media/aktualno/biznis-i-politika/hrvatska/eurostat-stop-a-nezaposlenosti-u-eu-stagnira-u-hrvatskoj-opada/>

¹² Lider, *Unatoč najvećem rastu, zaposlenost u Hrvatskoj najniža u EU*, 2018., dostupno na: <https://lider.media/aktualno/biznis-i-politika/hrvatska/unatoc-najvecem-rastu-zaposlenost-u-hrvatskoj-najniza-u-eu/>

2011. godini Hrvatska bilježi 8.534 doseljena stanovnika, a 2016. godine bilježi 13.985 doseljenika. Isto tako, bilježi se porast doseljenog stanovništva u iznosu od 38,98% od 2011. godine do 2016. godine.

Tablica 3. Odseljeno stanovništvo u inozemstvo u RH od 2011. do 2016. godine

Prostorna jedinica	Godina	Odseljeni u inozemstvo
REPUBLIKA HRVATSKA	2011	12.699
REPUBLIKA HRVATSKA	2012	12.877
REPUBLIKA HRVATSKA	2013	15.262
REPUBLIKA HRVATSKA	2014	20.858
REPUBLIKA HRVATSKA	2015	29.651
REPUBLIKA HRVATSKA	2016	36.436

Izvor: Izrada autora prema podacima Državnog zavoda za statistiku

Analizirajući podatke odseljenog stanovništva u inozemstvo u Republici Hrvatskoj u razdoblju od 2011. godine do 2016. godine može se zaključiti da se također radi o porastu odseljenog stanovništva iz Hrvatske u inozemstvo. U promatranom razdoblju Hrvatska bilježi u prosjeku 21.297 odseljena stanovnika. U 2011. godini Hrvatska bilježi 12.699 odseljenika, a 2016. godine 36.436 odseljenika. Kao što je već navedeno, Hrvatska bilježi porast odseljenog stanovništva u promatranih 6 godina te iznosi 65,15% od 2011. do 2016. godine. Stave li se u odnos doseljeno i odseljeno stanovništvo, može se zaključiti da je značajno veći postotak povećanja odseljenika nego doseljenog stanovništva.

Stope zaposlenosti su danas možda najvažniji, najcjelovitiji i najkompleksniji pokazatelji razvijenosti pojedinih društava. Iz njih se može iščitavati ne samo stanje ekonomije neke zemlje, već i ukupna modernost društva te relativno pouzdano i prognozirati, na temelju trendova u zaposlenosti, i stanje pojedinih država u budućnosti.¹³ Naime, iako je u fokusu šire javnosti problem nezaposlenosti već dugo prisutan i prepoznat kao društveni problem, istovremeno nije prepoznat u jednakoj mjeri i problem niske zaposlenosti, koji se ne može svesti samo na zapošljavanje (evidentiranih) nezaposlenih radnika. Isto tako, u Hrvatskoj trenutno svjedočimo procesu istovremenog smanjenja i zaposlenosti i nezaposlenosti stanovništva, što pokazuje da zapošljavanje nezaposlenih pomaže podizanju stope zaposlenosti, ali

¹³D.Vidović, *Zaposlimo Hrvatsku, Strateške smjernice za rast zaposlenosti*, Hrvatska gospodarska komora, Zagreb, 2015., str.11, dostupno na: http://predsjednica.hr/files/zaposlimo_hrvatsku_publikacija.pdf

da se manjak zaposlenih ne može nadomjestiti pukim smanjenjem nezaposlenosti. Niske stope zaposlenosti u hrvatskom slučaju povezane su ne samo sa visokom nezaposlenošću, strukturom te nezaposlenosti, već i kratkim radnim vijekom, niskom dobi umirovljenja, kasnim ulaskom u aktivnost, visokim udjelom sive ekonomije i neprijavljenog rada u BDP-u te neadekvatnim poreznim, obrazovnim, regionalnim, socijalnim i drugim javnim politikama, itd.¹⁴

Bićanić i Babić (2008.) tvrde da je za razumijevanje današnje situacije na hrvatskom tržištu rada od presudne važnosti u obzir uzeti neekonomske varijable i, kako tvrde, “ovisnost o putu”. To znači da su raspad bivše države, rat, tranzicija i proces privatizacije imali veliki utjecaj na situaciju današnjeg tržišta rada u Hrvatskoj. Prema njima, “ovisnost o putu” na hrvatskom tržištu rada ne ogleda se samo u trenutnim institucijama tržišta rada i demografskim trendovima, nego i u obrazovnoj strukturi nezaposlenog stanovništva te očekivanjima na strani ponude i na strani potražnje na tržištu rada. Franičević (2011.), s druge strane, ističe da je u razdoblju između 2000. i 2008. godine gospodarstvo u cjelini predstavljalo atraktivnu sliku s relativno visokim stopama rasta, rastom investicija, potrošnje i izravnih stranih ulaganja, stabilnošću cijena i tečaja, umjerenom fiskalnom konsolidacijom te povećanjem međunarodnih pričuva, što je dovelo i do povećanja zaposlenosti i pada nezaposlenosti. Međutim, isti naglašava kako je to razdoblje obilježeno i povećanjem trgovinskog deficita tekućeg računa, rasprostranjenom korupcijom, slabim pravosudnim sustavom i niskim kapacitetom za reforme. Upravo to je, uz niske stope aktivnosti, visoku neaktivnost i “ovisnost”, visoke stope dugotrajne nezaposlenosti, regionalne nejednakosti, naglasilo i produžilo utjecaj krize.¹⁵

Posljednje izvješće Europskog ureda za statistiku o troškovima rada u članicama Europske unije nudi mogući odgovor na pitanje zašto je teško naći adekvatne radnike u Hrvatskoj. Kako pokazuju najnoviji podaci s početka 2018. godine, Hrvatska je pri dnu prema troškovima rada po satu (uključujući nadnicu i druge troškove poput socijalnih doprinosa), ako se isključe javna uprava i poljoprivreda, a za kriterij uzmu poduzeća s najmanje deset zaposlenih. Iza hrvatskih 10,6 eura po satu u prošloj 2017. godini nalaze se samo Poljska (9,4 eura), Mađarska (9,1 eura), Latvija (8,1

¹⁴D. Vidović, op.cit. str.12

¹⁵I. Tomić, *Zaposlenost i nezaposlenost u Hrvatskoj – stanje, trendovi i kontekst*, Ekonomski institut, Zagreb, 2015, str.21, dostupno na: http://predsjednica.hr/files/zaposlimo_hrvatsku_publikacija.pdf

eura), Litva (8 eura), Rumunjska (6,3 eura) i Bugarska (4,9 eura), premda je prosjek EU 26,8 eura. Udio troškova koji se ne odnose na nadnicu u ukupnom trošku rada u hrvatskom slučaju iznosi 15%, što je jedan od najnižih. Osim Malte, manji udio troškova koji nisu nadnica u ukupnoj cijeni rada od Hrvatske imaju još samo Danska, Irska i Luksemburg. Prosječni trošak rada po satu u eurozoni iznosio je 30,3 eura, ukazuje statistika, ali su razlike na razini cijele Europske unije goleme.¹⁶

Nadalje, jednako kao što je usko povezana s kretanjem bruto domaćeg proizvoda kroz Okunov zakon, nezaposlenost se nalazi u jednoj vrlo važnoj relaciji za ekonomiste a to je inflacija koja se smatra makroekonomskim problemom. Ekonomisti su uočili da kada je stopa nezaposlenosti niska, inflacija ima tendenciju rasta i obrnuto, odnosno kada je stopa nezaposlenosti visoka, inflacija ima tendenciju opadanja. Navedeni negativan odnos po prvi puta je kvantitativno zabilježio novozelandačin A. W. Phillips iako se zasluge mogu pripisati i I. Fisheru koji je 1926. godine pronašao izuzetno visoku korelaciju između stope promjene cijena i zaposlenosti. Doprinos se i dan danas pripisuje Phillipsu te je nazvan Phillipsovom krivuljom. U osnovnom djelu iz 1958. godine u kojemu Phillips analizira gospodarstvo Ujedinjenog kraljevstva, Phillipsova krivulja opisuje zapravo povezanost između stope nezaposlenosti i promjene nadnica.¹⁷ Teoretski dio o Phillipsovoj krivulji, ali i gore spomenutom Okunovom zakonu je u poglavlju 5. gdje je isto detaljnije objašnjeno.

¹⁶V.Figenwald, *Hrvatska na dnu s cijenom nadnica po satu*, Lider, br.654, 2018., str.55

¹⁷S.Sharma, D.Tomić, op.cit., str. 95.

3. BRUTO I NETO PLAĆE U HRVATSKOJ

Plaća je iznos novca koji prima svaki zaposlenik od poslodavca na temelju radnih sati za njegov rad. U Hrvatskoj najčešće se radi o mjesečnim plaćama. Poslodavac od bruto plaće odbija iznose za pojedine poreze i doprinose te zaposlenik prima neto plaću. Bruto i neto plaće su osnovni pojmovi vezani za plaće radnika. Bruto plaća je iznos na koji se obračunava mirovinsko osiguranje, porezi i prirezi, a često se koristi termin *bruto 1*. Također, postoji i termin *bruto 2* koji označava ukupni trošak rada, odnosno označava minimalan iznos koji zaposlenik mora ostvariti svojim radom kako bi određeno poduzeće bilo na financijskoj nuli sa određenim zaposlenikom. Drugim riječima, *bruto 2* označava stvarni iznos novca koji svaki poslodavac daje za zaposlenika. Neto plaća je novac koji primi zaposlenik i ne označava iznos rada zaposlenika. Iznos rada je izražen u *bruto 2* plaći, a razliku između neto plaće i *bruto 2* plaće uzima država. To se može objasniti na jednostavnom primjeru - Prosječna hrvatska mjesečna neto plaća je 5.500 kuna. Takav iznos neto plaće za poslodavca iznosi 9.000 kuna. Omjer je 60% zaposleniku, a 40% državi, a sav trošak plaća poslodavac.¹⁸

Prema Zakonu o radu, članak 92. Isplata plaće i naknade plaće (NN 93/2014) navodi se:

1. Plaća se isplaćuje nakon obavljenog rada.
2. Plaća i naknada plaće isplaćuje se u novcu.
3. Ako kolektivnim ugovorom ili ugovorom o radu nije drukčije određeno, plaća i naknada plaće za prethodni mjesec isplaćuje se najkasnije do petnaestog dana u idućem mjesecu.
4. Plaća i naknada plaće su, u smislu ovoga Zakona, plaća i naknada plaće u bruto iznosu.

Nadalje, za izračun osnovne bruto plaće najčešće se koristi sljedeća formula:¹⁹

$$\text{BRUTO PLAĆA} = \text{Osnovica plaće} \times \text{koeficijent radnog mjesta} \times \text{faktor rada} \times \text{koeficijent minolog rada}$$

¹⁸ navedeni iznosi za plaću nisu na osnovi stvarne prosječne neto plaće u Hrvatskoj

¹⁹N.Crnički, *Bruto plaća*, 2014., dostupno na: <https://isplate.info/bruto-placa.aspx>

U bruto plaću ulaze sljedeće kategorije primitaka:²⁰

- primici od rada (redovan rad, prekovremeni rad, dodaci za rad u smjenama i turnusima, dodaci za rad subotom, nedjeljom i blagdanima i dr.)
- naknade za bolovanje na teret poslodavca
- naknade za godišnji odmor, plaćene dopuste i dr.
- naknade za blagdane
- dodaci na minuli rad, posebne uvjete rada, znanstveni stupanj i dr.
- plaća u naravi

Potrebno je ukazati i na razliku između nominalne i realne plaće. Razlika između nominalne i realne plaće označava razliku između onoga što zaposlenik dobije u obliku novca i onoga što za dobiveni novac može kupiti. Drugim riječima, realna plaća je nominalna plaća korigirana za inflaciju. Upravo zato inflacija može narušiti porast nominalnih plaća, a s druge strane deflacija može uvećati. Rast, a potom i pad realnih plaća većina ekonomista u suštini objašnjava time što u prvom slučaju dolazi do gospodarskog rasta, a u drugom slučaju do gospodarskog pada. Gospodarski rast označava povoljnu situaciju u realnom sektoru, odnosno otvaranje novih radnih mjesta, porast nominalnih plaća koji je veći od inflacije što znači i porast realnih plaća. Upravo na taj način životni standard radnika raste u vremenima gospodarskog rasta. S druge strane, kriza označava gospodarski pad, a za posljedice ima nepovoljnu situaciju u realnom sektoru, pad dobiti, otpuštanje radnika, smanjenje nominalnih plaća što ujedno znači i pad životnog standarda radnika.²¹

U nastavku (Tablica 4.) prikazane su prosječne bruto plaće u Hrvatskoj od 1999. godine do 2016. godine prema podacima Državnog zavoda za statistiku.

²⁰ Ibid.

²¹ D. Birač, *Što se događa s realnim plaća u Hrvatskoj?*, 2014., dostupno na: <http://www.index.hr/vijesti/clanak/sto-se-dogadja-s-realnim-placama-u-hrvatskoj/742804.aspx>

Tablica 4. *Prosječne bruto plaće u Hrvatskoj u kunama*²²

GODINA	BRUTO PLAĆA
1999.	4.551
2000.	4.869
2001.	5.061
2002.	5.366
2003.	5.623
2004.	5.985
2005.	6.248
2006.	6.634
2007.	7.047
2008.	6.544
2009.	7.711
2010.	7.679
2011.	7.796
2012.	7.875
2013.	7.939
2014.	7.953
2015.	8.055
2016.	7.752

Izvor: Državni zavod za statistiku, Statistički ljetopis (2006., 2010., 2017.)

Prema podacima može se zaključiti da prosječne mjesečne bruto plaće u Hrvatskoj imaju tendenciju rasta. Izuzetak su 2008. godina, 2010. godina te 2016. godina kada se bilježi pad bruto plaća. Od promatrane 1999. godine do promatrane 2016. godine prosječne bruto plaće su porasle za 41,29%. Najveći porast bruto plaća bilježi se u 2009. godini kada je ista porasla za 15,13% u odnosu na 2008. godinu. Značajan porast bilježi se i u 2000. godini kada je bruto plaća porasla za 6,53% u odnosu na prethodnu 1999. godinu. Nadalje, najznačajniji pad prosječnih bruto plaća unutar promatranih godina bilježi se u 2008. godini kada ista bilježi pad od 8,40% u odnosu na 2007. godinu. Isto tako, bruto plaća je u 2010. godini pala za 0,42% u odnosu na prethodno promatranu godinu te u 2016. godini kada ista bilježi pad za 3,76% u odnosu na 2015. godinu.

²²Podaci o prosječnim mjesečnim isplaćenim bruto plaćama prate se redovitim mjesečnim istraživanjem kojim je obuhvaćeno 70% zaposlenih u svakom odjeljku Nacionalne klasifikacije djelatnosti 2002. (za podatke do 2005.) te Nacionalne klasifikacije 2007 (za podatke od 2006. do 2016.). Istraživanjem se prikupljaju podaci od pravnih osoba svih oblika vlasništva, tijela državne vlasti te tijela jedinica lokalne i područne (regionalne) samouprave na području Republike Hrvatske.

Prema novijim podacima, službena statistika Državnog zavoda za statistiku ukazuje da je prosječna mjesečna bruto plaća za prvi mjesec 2018. godine iznosila je 8.361 kuna što je nominalno više za 3,8%, a realno za 4% u odnosu na prosinac 2017.

Također, u nastavku (Tablica 5.) prikazane su prosječne neto plaće u Hrvatskoj od 1999. godine do 2016. godine prema podacima Državnog zavoda za statistiku.

Tablica 5. *Prosječne neto plaće u Hrvatskoj u kunama*²³

GODINA	NETO PLAĆA
1999.	3.055
2000.	3.326
2001.	3.541
2002.	3.720
2003.	3.940
2004.	4.173
2005.	4.376
2006.	4.603
2007.	4.841
2008.	5.178
2009.	5.311
2010.	5.343
2011.	5.411
2012.	5.748
2013.	5.515
2014.	5.533
2015.	5.711
2016.	5.685

Izvor: Državni zavod za statistiku, Statistički ljetopis (2006., 2010., 2017.)

Prema podacima može se zaključiti da prosječne neto plaće u Hrvatskoj imaju tendenciju rasta s izuzetkom 2013. godine i 2016. godine. Od 1999. godine do promatrane 2016. godine, prosječna neto plaća porasla je za 46,26%. Najveći porast neto plaća bilježi se u 2000. godini kada je neto plaća porasla za 8,15% u odnosu na 1999. godinu. Isto tako, značajan porast neto plaća zabilježen je u 2008. godini kada je ista porasla za 6,51% u odnosu na godinu prije, odnosno 2007. godinu. Kao što je već spomenuto, neto plaće u 2013. godini bilježe pad za 4,05% u odnosu na 2012.

²³ Podaci o prosječnim mjesečnim isplaćenim neto plaćama prate se redovitim mjesečnim istraživanjem kojim je obuhvaćeno 70% zaposlenih u svakom odjeljku Nacionalne klasifikacije djelatnosti 2002. (za podatke do 2005.) te Nacionalne klasifikacije 2007 (za podatke od 2006. do 2016.). Istraživanjem se prikupljaju podaci od pravnih osoba svih oblika vlasništva, tijela državne vlasti te tijela jedinica lokalne i područne (regionalne) samouprave na području Republike Hrvatske.

godinu, dok se u 2016. godini u odnosu na prethodnu 2015. godinu bilježi pad istih za 0,46%.

Prema podacima Državnog zavoda za statistiku i prema najnovijim podacima, prosječna neto plaća po zaposlenom u Hrvatskoj isplaćena za siječanj 2018. godine iznosila je 6.189 kuna, što je nominalno više za 3,6%, a realno za 3,8% u odnosu na prosinac 2017.

Obratimo pozornost i na zaposlene u pravnim osobama gdje je najviša prosječna mjesečna neto plaća po zaposlenom u pravnim osobama isplaćena za travanj u 2017. godini zaposlenima u financijskim uslužnim djelatnostima, osim osiguranja i mirovinskih fondova, i iznosila je 10.047 kuna, dok su najnižu u iznosu od 3.532 kuna imali zaposleni u proizvodnji odjeće. Prosječna mjesečna bruto plaća za četvrti mjesec 2017. godine iznosila je 7.945 kuna te je prema travnju 2016. nominalno bila veća za 3,3 posto, a realno za 1,9 posto. Na mjesečnoj razini, u odnosu na ožujak, prosjek bruto plaće isplaćene za travanj bio je nominalno dva posto, a realno 2,5 posto niži.²⁴

Nadalje, važno je naglasiti i minimalne plaće. Minimalna plaća je najmanji iznos plaće koji poslodavac smije isplatiti djelatniku za određeni mjesečni broj radnih sati. Prema novijim podacima, visina minimalne plaće za razdoblje od 1. siječnja do 31. prosinca 2017. u bruto iznosu iznosi 3.276 kuna. U Hrvatskoj do 2008. godine nije postojala uobičajena "prava" minimalna plaća, ali je od 1998. godine na nacionalnoj razini postojala najmanja osnovica za plaćanje doprinosa za zdravstveno i mirovinsko osiguranje, koja je ustvari imala funkciju utvrđenog iznosa minimalne plaće. Tijekom gotovo deset godina navedena minimalna plaća ostala je razmjerno stabilna i iznosila trećinu prosječne plaće.²⁵

Prema podacima Eurostata, minimalne plaće u članicama Europske unije kreću se u širokom rasponu, od onih u mjesečnom iznosu manjem od 500 eura u zemljama na

²⁴ Poslovni.hr/Hina, *Prosječna bruto plaća u Hrvatskoj iznosi 7.945 kuna, 2017.*, dostupno na: <http://www.poslovni.hr/hrvatska/prosjecna-bruto-placa-u-hrvatskoj-iznosi-7945-kuna-329549>

²⁵ P.Bejaković, *Problemi, mogućnosti i ograničenja postojanja minimalne plaće u Hrvatskoj*, Profil javne politike, 2015, br.24, str.25, dostupno na: <https://hrcak.srce.hr/156899>

istoku Unije, uključujući i Hrvatsku, do onih od 1.000 eura u sjeverozapadnim članicama. Minimalna plaća u Bugarskoj iznosi 235 eura, u Rumunjskoj 275, u Latviji i Litvi 380 eura. U Češkoj minimalna plaća iznosi 407 eura, u Mađarskoj 412, u Hrvatskoj 433. Slijede Slovačka sa 435 eura, Poljska s 453 eura te Estonija s 470 eura. U pet članica smještenih na jugu Europske unije minimalne su plaće u rasponu od 500 eura do 1.000 eura. U tu skupinu ulaze Portugal sa 650 eura, Grčka sa 684, Malta sa 736 eura, te Slovenija i Španjolska sa 805 odnosno 826 eura. U ostalih sedam zemalja članica na zapadu i sjeveru Europske unije, minimalne plaću su iznad 1.000 eura. Minimalna plaća u Velikoj Britaniji iznosi 1.397 eura, u Francuskoj 1.480 eura, u Njemačkoj 1.498 eura, u Belgiji 1.532 eura te u Nizozemskoj 1.552 eura. U Irskoj je minimalna plaća 1.563 eura te u Luksemburgu iznosi daleko najviše u iznosu od 1.999 eura.²⁶

Nadalje, ponekad se može pomisliti kako će neka gospodarska grana, ako zakon za nju odredi više plaće i nadnice, povećati cijene svojih proizvoda, te će se tako teret za isplatu viših nadnica prebaciti na potrošače, odnosno kupce proizvoda. Međutim, upravo ovakva prebacivanja se ne mogu tako lako izvesti, kao što se ne mogu ni lako izbjeći posljedice umjetno podignutih plaća i nadnica. Možda nije moguće povećati cijenu određenog proizvoda, s obzirom na to da će potrošači početi kupovati isti takav proizvod iz uvoza ili će pronaći adekvatnu zamjenu. S druge strane, ako potrošači i nastave kupovati proizvod kojem je povećana cijena, kupovat će ga u manjim količinama. Isto tako, neki radnici će imati koristi jer će se povećati njihove plaće i nadnice, međutim, drugi će ostati bez radnog mjesta zbog smanjenog obujma prodaje. S druge strane, ako se cijena proizvoda ne poveća, iz posla u toj grani bit će istisnuti marginalni proizvođači. Tako će opet doći do smanjenja proizvodnje, a samim time i povećanja nezaposlenosti, samo na drugi način.²⁷

Kada se upozori upravo na gore navedene posljedice, postoje razna mišljenja koja ukazuju da ako određena grana ne može preživjeti, osim ako ne isplaćuje sramotne nadnice, minimalne će je plaće potpuno dotući. Upravo u tome mišljenju, odnosno stajalištu, zanemaruju se stvarne posljedice. Prije svega, činjenica da će potrošači

²⁶ *Stiglo novo izvješće o minimalnim plaćama: Evo u kojim zemljama je minimalac najveći i kako stoji Hrvatska*, (2017.), dostupno na: <https://net.hr/danas/hrvatska/stiglo-novo-izvjesce-o-minimalnim-placama-evo-u-kojim-zemljama-je-minimalac-najveci-i-kako-stoji-hrvatska/>

²⁷ P.Bejaković, op.cit., str.24.

biti oštećeni jer više neće imati taj proizvod u ponudi. Također, zanemaruje se da će ljudi koji rade za tu gospodarsku granu biti osuđeni na nezaposlenost. I konačno, koliko god bile sramotne plaće i nadnice u promatranoj gospodarskoj grani, one su se njezinim radnicima činile najboljima među svim mogućnostima koje su im na raspolaganju, jer bi inače sami napustili taj posao i pronašli bolji. Ako se neka grana ugasi zbog zakona o minimalnim plaćama i nadnicama, njezini će radnici biti primorani okrenuti se opcijama koje su im manje privlačne. Pritom će njihovo nadmetanje za posao u tim alternativnim zanimanjima dovesti i do pada plaća i nadnica u njima.²⁸ Prema tome, ne može se izbjeći zaključak kako minimalne plaće i nadnice samo povećavaju nezaposlenost.

Podaci koje je objavio HNB u publikaciji iz 2015. godine, koji su prikupljeni tijekom provođenja Ankete o tržištu rada i određivanju plaća u Hrvatskoj, koja je provedena tijekom druge polovine 2014. godine u sklopu projekta istraživačke mreže za dinamiku plaća Europske središnje banke, pokazuju da su najrasprostranjeniji gospodarski šokovi kojima su poduzeća bila izložena u razdoblju od 2010. do 2013. godine bili šok nelikvidnosti, šok potražnje te nepovoljni uvjeti financiranja. Poduzeća su se nepovoljnim gospodarskim uvjetima prilagodila smanjivanjem troškova poslovanja, ponajviše smanjivanjem troškova rada. Glavna strategija smanjivanja troškova rada bilo je smanjenje broja zaposlenih osoba, i to individualna otpuštanja, ali i neobnavljanje privremenih ugovora pri isteku te zamrzavanje i smanjenje novih zapošljavanja. U prvim godinama krize relativno mali udio poduzeća u Hrvatskoj smanjivao je nominalne plaće nastojeći se prilagoditi negativnom gospodarskom šoku, no taj se udio iz godine u godinu povećavao, kao i postotak radnika obuhvaćenih smanjenjem plaća. Iako ovaj podatak upućuje na smanjivanje rigidnosti plaća u Hrvatskoj, prema drugim pokazateljima formiranje plaća u Hrvatskoj ne možemo smatrati fleksibilnim. Tako znatan udio poduzeća mijenja plaće rjeđe nego jednom godišnje, trećina poduzeća indeksira plaće u odnosu na inflaciju, a kolektivni ugovori reguliraju plaće za oko polovinu zaposlenih u privatnom sektoru.²⁹

²⁸ P. Bejaković, op.cit., str.24.

²⁹ M. Kunovac, A. Pufnik, *Obilježja tržišta rada i određivanja plaća u Hrvatskoj: rezultati Anketa poduzeća*, Hrvatska narodna banka, 2015., str.1, dostupno na: <http://www.hnb.hr/documents/20182/265578/p-027/28c3339e-b94a-4fc6-8c0a-626f1738a6cb>

Nadalje, u Anketi se pokušalo ispitati i u kojoj mjeri je u hrvatskom gospodarstvu prisutna (ne)fleksibilnost promjene osnovnih plaća. Brojna istraživanja su pokazala da je upravo plaća jedan od glavnih razloga koji u nepovoljnim gospodarskim uvjetima utječe na to da se teret prilagodbe troškova poslovanja prebaci na smanjenje broja zaposlenih. Unatoč krizi prosječne nominalne plaće u hrvatskom gospodarstvu rasle su, iako se intenzitet rasta usporio u odnosu na razdoblje prije krize.³⁰

U istoj Anketi se kao indikator rigidnosti nominalnih plaća naniže uzima udio poduzeća koji je u određenom razdoblju zamrznuo i/ili smanjio osnovne plaće. Rezultati Ankete pokazuju da je u prvim godinama gospodarske krize, točnije u 2010. godini, relativno mali udio poduzeća, odnosno 7%, u Hrvatskoj smanjivao plaće nastojeći se prilagoditi negativnom gospodarskom šoku, no taj se udio iz godine u godinu povećavao te je u 2013. godini dosegnuo 16%. Pritom se udio poduzeća koja su smanjivala plaće tijekom spomenutog razdoblja najviše povećao u građevinarstvu te kod velikih poduzeća. Isto tako, postotak radnika obuhvaćenih smanjenjem plaća znatno se povećao, sa 76% u 2010. godini na 96% u 2013. godini. S druge strane, znatan i relativno stabilan udio poduzeća, približno 13%, tijekom kriznih godina zamrznuo je plaće te je postotak obuhvaćenih radnika u svim godinama bio viši od 90%. Iz spomenutog proizlazi da se u Hrvatskoj tijekom krize u određenoj mjeri povećala fleksibilnost nominalnih plaća naniže.³¹

Rigidnost realnih plaća naniže ocijenjena je, u Anketi, indikatorom raširenosti indeksacije plaća, tj. prakse poduzeća da prilagođavaju promjene osnovne plaće kretanju inflacije. Utvrđeno je da je prije 2010. godine znatan udio poduzeća, oko 42%, indeksirao plaće u odnosu na inflaciju, dok se u razdoblju od 2010. godine do 2013. godine taj udio smanjio na 34%, no i nadalje je ostao visok. Najveća prilagodba, odnosno smanjenje realne rigidnosti plaća zabilježeno je u djelatnostima trgovine i prerađivačke industrije te kod velikih poduzeća.³²

U znanstvenom članku u kojemu su analizirane razlike između plaća unutar javnog sektora, poduzeća u državnom vlasništvu i privatnog sektora, odnosno uspoređeno

³⁰ M. Kunovac, A. Pufnik, op.cit., str. 10

³¹ ibidem

³² ibidem

je stanje i kretanje neto plaća po satu rada u javnom sektoru, poduzećima u državnom vlasništvu i privatnim poduzećima u Hrvatskoj na temelju podataka iz Ankete o radnoj snazi u razdoblju od 2000. godine do 2012. godine. Rezultati pokazuju da je 2000. godine prosječna plaća u javnom sektoru bila gotovo 40% veća nego u privatnom, ali da se ta razlika smanjila na oko 25% u 2008. godini i 2012. godini. Razlika između poduzeća u državnom vlasništvu i privatnih poduzeća nešto je manja – 18% u 2012. godini. Detaljnija kvantitativna analiza koja je koristila regresijske ocjene i metodu dekompozicije, pokazuje da je prilagođeni jaz plaća, odnosno razlika u plaćama korigirana za međusektorske razlike u karakteristikama radnika i radnog mjesta, znatno manji nego jaz mjeren usporedbom prosječnih plaća. Regresijska analiza pokazuje da je prilagođena premija u korist javnog sektora, u odnosu na privatni, 2000. godine iznosila 18%, a tijekom promatranog razdoblja kontinuirano se smanjivala te je 2012. godine iznosila 5%.³³

³³D.Nestić, I.Rubil, I.Tomić, Analiza razlika u plaćama između javnog sektora, poduzeća u državnom vlasništvu i privatnog sektora u Hrvatskoj 2000.-2012., Privredna kretanja i ekonomska politika, Zagreb, god.24, br.1 (136), 2015., dostupno na: <https://hrcak.srce.hr/140042>

4. INFLACIJA U HRVATSKOJ


Inflacija je jedan od najvažnijih ekonomskih pojmova i predstavlja povećanje cijena proizvoda i usluga unutar nekog gospodarstva. Drugim riječima, inflacija je stopa po kojoj su se cijene proizvoda i usluga povećale u određenom vremenskom razdoblju te se zbog takve pojave smanjuje kupovna moć stanovništva u određenom gospodarstvu. Inflacija također označava stanje u kojemu novac gubi na vrijednosti. Jedan od razloga inflacije je taj da količina ukupnog novca brže raste od količine proizvedene robe ili usluga. Kada je potražnja veća od ponude, roba i usluge se mogu prodavati po višoj cijeni, a za potrošače to znači da će produkti biti skuplji. Drugi razlog rasta inflacije može biti zbog nestašice sirovina, rasta troškova proizvodnje ili porasta plaća. U radu je inflacija analizirana iz različitih aspekata zbog vrlo širokog razumijevanja inflacije. Isto tako, u metodološkom dijelu rada, analizirana je temeljna inflacija koja izostavlja cijene poljoprivrednih proizvoda i energije, no u teoretskom dijelu prikazana je i problematika inflacije kao općenitog pojma te jednog od najvažnijih ekonomskih pojava.

U gospodarstvu mogući su tzv. *udari cijena*, a oni se mogu nazvati i inflatornim udarima. Udari cijena mogu doći zbog pretjeranog rasta nominalnih nadnica koje tvrtke dalje prenose u obliku povećanih cijena proizvoda. Takvi se udari mogu nazvati nadnično-troškovnom inflacijom. U slučaju da se monetarna vlast ne prilagodi takvome udaru, cijene nastavljaju rasti, a output i zaposlenost padati. U određenom se trenutku rastuće nadnice i rastuća nezaposlenost prestaju međusobno natjecati. Postoji mogućnost da radnici zadrže visoke realne nadnice, ali i dalje ne bi smjeli zahtijevati nominalne nadnice veće od proizvodnosti rada. Također, moguće je da nadnice padnu zbog dugotrajne nezaposlenosti. U tom slučaju doći će do obrata u udaru ponude. Ukoliko dođe do suprotne situacije i monetarna vlast se odluči na prilagodbu situaciji povećanjem ponude novca doći će do porasta nadnica i cijena. Radnici neće biti u boljem položaju jer se nadnični dobici izgube s porastom cijena. Ako se taj proces natjecanja većih nadnica i većih cijena nastavlja može nastati spirala dviju pojava. Spomenuta spirala može se zaustaviti jedino ako se monetarna

vlast odluči na neprilagođavanje udaru ponude i nepovećanje mase novca u optjecaju.³⁴

Nužan uvjet za funkcioniranje gospodarstva, ali i za stvaranje djelotvornih institucija i mjera ekonomske politike, postojanje monetarne obračunske jedinice s više ili manje pouzdanom stabilnom realnom kupovnom moći. Zašto to često nije moguće ostvariti je upravo postojanje inflacije, odnosno porasta opće razine cijena roba i usluga izraženih u novcu. Uzroke inflatornih pritisaka mogu se, uglavnom, dijeliti na one koji proizlaze iz inflacije potražnje i one koji proizlaze iz inflacije troškova. Cjenovnu inflaciju je moguće promatrati i kroz širi okvir pa se može reći da se inflacija razlikuje prema uzrocima (inflacija potražnje, inflacija ponude, inflacija troškova, inflacija profita, financijska inflacija, kreditna inflacija, itd.) i prema brzini povećanja cijena (puzajuća inflacija, umjerena inflacija, galopirajuća inflacija i hiperinflacija). Razlike između inflacija ne mora se pretjerano naglašavati jer često se javljaju situacije u kojima se različiti uzroci međusobno isprepleću.³⁵ Promatrajući stanje u Hrvatskoj može se zaključiti da Hrvatska nema zabrinjavajućih problema s inflacijom. U nastavku (Grafikon 1. i Tablica 6.) prikazano je kretanje inflacije u Hrvatskoj od siječnja 2011. godine do veljače 2018. godine jer su iz preuzetog izvora podaci dostupni od 2011. godine. Isto tako, raspon godina u tablicama i grafikonima nije svugdje isti jer su različiti izvori te svaki izvor ne nudi podatke sve od 1999. godine kako se analizira u metodološkom dijelu. No u ovome teoretskom dijelu cilj je prikazati trenutno stanje, odnosno novije razdoblje u Hrvatskoj.

Grafikon 1. *Kretanje inflacija u Hrvatskoj od 2011. godine do 2018. godine*



Izvor: DZS, preuzeto sa: <http://www.nhs.hr/gospodarstvo/pokazatelji/inflacija/?od=201101&do=201802>

³⁴ A. Bogunović, S. Sharma, *Narodno gospodarstvo: osnove teorije i prakse*, Art Studio Azinović, Zagreb, 1995., str. 65.

³⁵ S. Sharma, D. Tomić, op.cit., str. 95-96.

Tablica 6. *Inflacija u Hrvatskoj od 2011.godine do 2017. godine po mjesecima*

MJESEC	2011	2012	2013	2014	2015	2016	2017
siječanj	1,90%	1,20%	5,20%	0,10%	-0,90%	-0,80%	0,90%
veljača	2,20%	1,30%	4,90%	-0,60%	-0,40%	-1,40%	1,40%
ožujak	2,60%	2,00%	3,70%	-0,40%	0,10%	-1,70%	1,10%
travanj	2,40%	2,60%	3,30%	-0,50%	-0,10%	-1,70%	1,40%
svibanj	2,50%	3,90%	1,60%	-0,20%	0,00%	-1,80%	1,10%
lipanj	2,00%	3,80%	2,00%	-0,40%	0,00%	-1,60%	0,70%
srpanj	1,90%	3,40%	2,30%	-0,10%	-0,40%	-1,50%	0,80%
kolovoz	2,00%	4,00%	1,90%	-0,30%	-0,60%	-1,50%	1,00%
rujan	2,20%	5,00%	1,10%	-0,20%	-0,80%	-0,90%	1,40%
listopad	2,60%	4,80%	0,20%	0,40%	-0,90%	-0,50%	1,40%
studen	2,60%	4,40%	0,40%	0,20%	-0,90%	-0,20%	1,40%
prosinac	2,10%	4,70%	0,30%	-0,50%	-0,60%	0,20%	1,20%

Izvor: DZS, preuzeto sa: <http://www.nhs.hr/gospodarstvo/pokazatelji/inflacija/?od=201101&do=201802>

Iz Grafikona 1. koji je povezan sa Tablicom 6. može se zaključiti da je pozitivna stopa inflacije bila sve do siječnja 2014. godine. Od veljače 2014. godine do kraja 2016. godine u prosjeku je vladala negativna stopa inflacije (izuzetak je listopad i studeni u 2014. godini te ožujak, svibanj i lipanj u 2015. godini). Krajem 2016. godine i početkom 2017. godine inflacija se „vratila“ u Hrvatsku. Uočavalo se poskupljenje hrane u prodavaonicama, građani su više novaca morali izdvajati za prijevoz, te se za istu uslugu ugostiteljima izdvajalo više novaca. Budući da su neto plaće u Hrvatskoj u proteklih godinama blago porasle, građani su se nadali boljem životnom standardu. S druge strane, građani strahuju da će poskupljenja „izjedati“ povišicu plaća te da će se životni standard ugroziti.

Državni zavod za statistiku u 2017. godini objavio je da su potrošačke cijene u veljači porasle za 1,4% u odnosu na veljaču u 2016. godini, što se vidi u Grafikonu 2. prema indeksu potrošačkih cijena. Povećanje cijena se dogodilo nakon tri godine deflacije, što se vidi prema indeksu potrošačkih cijena te je vidljivo i u Tablici 7. te Grafikonu 1., odnosno razdoblju u kojemu su cijene u Hrvatskoj sustavno padale što u „modernoj povijesti“ Hrvatske još nije zabilježeno.

Grafikon 2. *Indeksi potrošačkih cijena (promjena u odnosu na isti mjesec prethodne godine)*



Izvor: Ekonomski lab, prema podacima Državnog zavoda za statistiku, dostupno na:

<https://arhivanalitika.hr/blog/inflacijski-ciklus-treci-put-u-malo-vise-od-10-godina-koliko-jako-ovaj-put/>

Isto tako, promatrajući Grafikon 2. može se zaključiti da tek sada slijedi „pumpanje“ cijena energenata u ostale cijene te uobičajeni sezonski rast cijena usluga rekreacije, kulture, hotela i restorana. Nadalje, očito je da će krivulja prikazana u Grafikonu 2. i dalje imati tendenciju rasta, što će označavati vrhunac trećega cjenovnog ciklusa u proteklih 10 godina. Isto tako, vrhunac nedavna dva ciklusa vidi se u 2008. godini te u 2012. godini. U nastavku su sažeto prikazani indeksi potrošačkih cijena preuzeti sa Državnog zavoda za statistiku i potvrđuju gore navedene činjenice.

Tablica 7. *Indeksi potrošačkih cijena*³⁶

2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.
<u>100,0</u>	106,1	108,6	109,7	112,2	116,1	118,6	118,4	117,8	116,5
94,3	<u>100,0</u>	102,4	103,5	105,8	109,4	111,8	111,6	111,1	109,8
92,1	97,7	<u>100,0</u>	101,1	103,3	106,9	109,2	109,0	108,5	107,3
91,1	96,7	99,0	<u>100,0</u>	102,3	105,8	108,1	107,9	107,4	106,2
89,1	94,5	96,8	97,8	<u>100,0</u>	103,4	105,7	105,5	105,0	103,8
86,2	91,4	93,6	94,6	96,7	<u>100,0</u>	102,2	102,0	101,5	100,4
84,3	89,4	91,5	92,5	94,6	97,8	<u>100,0</u>	99,8	99,3	98,2
84,5	89,6	91,7	92,7	94,8	98,0	100,2	<u>100,0</u>	99,5	98,4
84,9	90,0	92,2	93,1	95,2	98,5	100,7	100,5	<u>100,0</u>	98,9
85,8	91,0	93,2	94,2	96,3	99,6	101,8	101,6	101,1	<u>100,0</u>

Izvor: Državni zavod za statistiku, Statistički ljetopis 2017.

³⁶ Indeksi se čitaju samo vodoravno. Indeksi su izračunati iz baznih indeksa (2015.=100)

Većina ekonomista se slaže da je rast cijena poželjan ako je umjeren. Inflacija je redovita popratna pojava svakog gospodarskog napretka. Smatra se da je prihvatljiva stopa inflacije koja ne prelazi 10% godišnje. Međutim, deflacija, koja je u Hrvatskoj od 2014. godine dovela do padanja cijena u rasponu od 0,2% do 1,1% godišnje, najčešće negativna pojava. Deflacija je zapravo znak gospodarske stagnacije, rasta dugova i kolektivnog propadanja. Predsjednik Nezavisnih hrvatskih sindikata (NHS) Krešimir Sever naglasio je kako blaga inflacija nije loša, ali da postoji strah da će poskupljenja biti „udarac“ na kućne proračune građana, osobito na umirovljenike kojima mirovine u proteklih nekoliko godina su bez kretanja, odnosno povećanja. Drugim riječima, Hrvatskoj je potreban snažniji rast plaća, što bi omogućilo i povećanje mirovina. Prema mišljenju Ljube Jurčića, profesora na Ekonomskom fakultetu u Zagrebu, građani se ipak ne bi trebali bojati brzog rasta cijena, jer kako on tvrdi, za to u Hrvatskoj ne postoje uvjeti. Blaga inflacija, prema njegovim riječima, pozitivno utječe na gospodarstvo. Kad gospodarski rast dosegne određenu točku, onda on potiče sam sebe, vlastito ubrzavanje. Inflaciju, pak, potiču dva osnovna razloga, a to su veći troškovi i veća potražnja.³⁷

U svojem poznatom radu Kydland i Prescott (1977.) pokazuju kako nemogućnost kreatora ekonomske politike da se obvežu na politiku niske inflacije može dovesti do rasta inflacije unatoč nepostojanju dugoročnog tradeoffa između inflacije i outputa. Kydland i Prescott polaze od modela gospodarstva u kojem poremećaji na strani agregatne potražnje imaju realne učinke, a očekivanja inflacije utječu na agregatnu ponudu. Kydland i Prescott pretpostavljaju da je ova razina outputa pri fleksibilnim cijenama niža od socijalno optimalne razine, što može biti posljedica pozitivnih graničnih stopa poreza ili nesavršene konkurencije. Također, oni pretpostavljaju da je inflacija nakon neke razine skupa i da granični trošak inflacije raste s porastom iste.³⁸

U središnjim bankama širom svijeta predviđanje inflacije je dobilo značajnu ulogu, i u promišljanju politike, i u komuniciranju s javnosti kao što su bili slučajevi središnjih banaka u Engleskoj, Švedskoj, Norveškoj, Novom Zelandu i dr., a koje su vodile monetarnu politiku na temelju procedure koja se odnosi na ciljano predviđanje

³⁷B.Podgornik, *Nakon tri godine u Hrvatsku se vratila inflacija: Evo što to zapravo znači*, 2017., dostupno na: http://www.novilist.hr/Vijesti/Hrvatska/Nakon-tri-godine-u-Hrvatsku-se-vratila-inflacija-Evo-sto-to-zapravo-znaci?meta_refresh=true

³⁸Đ.Benić, *Monetarna politika: transparentnost središnje banke i ciljana inflacija*, EKONOMSKA MISAO I PRAKSA DBK. GOD XXIII. (2014.) Br. 1., str. 236, dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=182466

inflacije. U takvom pristupu središnje banke daju kvantitativnu projekciju očekivanih budućih gospodarskih kretanja zasnovanih na tome kako središnje banke namjeravaju kontrolirati kratkoročne kamatne stope i takvu projekciju daju na javnu raspravu. Tako je tijekom protekla dva desetljeća ciljana inflacija postala osobito popularna u provođenju monetarne politike.³⁹

U Hrvatskoj je temeljna mjera inflacije indeks potrošačkih cijena koji se koristi od 2004. godine. Značajno je za naglasiti i temeljnu inflaciju, koja će se i analizirati unutar ovoga rada, jer je ona uz indeks potrošačkih cijena prateći indikator kretanja cijena dobara i usluga. Isto tako, razlog odabira varijable temeljne inflacije je ta što je guverner Hrvatske narodne banke Boris Vujčić izjavio da mjera kretanja cijena u privredi je vrlo važna za vođenje monetarne politike jer se radi o mjeri kretanja razine cijena koja ovisi o ponudi i potražnji, zbog toga što se isključuju izrazito volatilne cijene poput poljoprivrednih prehrambenih proizvoda, kao i one koje su regulirane, i ona pomaže u raspoznavanju jesu li promjene kretanja potrošačkih cijena uzrokovane kratkoročnim poremećajima ili postoje određeni dugoročni trendovi.⁴⁰ Temeljna inflacija isključuje cijene iz prehrambenih i energetske sektora jer su znatno nestabilne te se kao najčešća mjera za izračunavanje koristi upravo indeks potrošačkih cijena (CPI). Prema Hrvatskoj narodnoj banci (HNB) temeljna inflacija se izračunava tako da se iz cijena na malo izvuku proizvodi koji su pod visokim sezonskim oscilacijama cijena kao npr. poljoprivredni proizvodi te proizvodi na čije cijene utječe država, a to mogu biti struja, plin i slično. Na cijene tih proizvoda, određene administrativno, monetarna politika ne može utjecati. Razlog zašto se cijene poljoprivrednih proizvoda i energije izdvajaju iz izračuna temeljne inflacije je taj što s porastom cijena hrane stanovništvo će i dalje kupovati hranu, jer hrana je neophodna za život. Isto tako, povećanjem cijene goriva, spremnik automobila se mora napuniti kako bi vozili automobil. Značajno je mjeriti temeljnu inflaciju jer odražava odnos između cijena roba i usluga te prihoda potrošača. Ako se roba i usluge s vremenom povećavaju, a prihod potrošača ne, potrošači će imati slabiju kupovnu moć jer se vrijednost novca smanjuje u odnosu na vrijednost osnovnih dobara i usluga. Isto tako, jedan od razloga odabira varijable temeljne inflacije u

³⁹Đ. Benić, op.cit. str. 242

⁴⁰S. Jakšić, T. Škrinjar, *Analizaučinaka odabranih makroekonomskih varijabli na inflaciju u Hrvatskoj za razdoblje 2000. - 2009. godine*, Zbornik Ekonomskog fakulteta u Zagrebu, godina 8, br.2, 2010. str.99, dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=105345

metodološkom dijelu ovoga rada je ta što je guverner Hrvatske narodne banke Boris Vujčić izjavio da se na temelju gore navedeno: „*gleda samo na temeljnu inflaciju kao na nešto na što mora reagirati*“.

Nadalje, analizirajući najnovije podatke Hrvatske narodne banke (HNB) dolazi se do zaključka da je temeljna inflacija u 2017. godini ubrzana što se odražava u poskupljenju prehrambenih proizvoda i rasta cijena ugostiteljskih usluga zbog povećanja stope PDV-a. Isto tako, ubrzavanje temeljne inflacije odražava, u određenoj mjeri, i neizravne učinke rasta svjetskih cijena sirovina na cijene ulaznih proizvoda za proizvodnju nekih industrijskih proizvoda. Osim toga, jačanje domaće potražnje također je pogodovalo rastu temeljne inflacije. Cjenovni pritisci koji proizlaze iz troškova rada u 2017. godini bili su prigušeni zbog smanjenja jediničnih troškova rada. Nadalje, blagi negativan učinak na ukupnu inflaciju imalo je smanjenje stope PDV-a na električnu energiju, a ublažilo ga je povećanje stope PDV-a na šećer i ugostiteljske usluge, rast trošarina na cigarete i automobile te povećanje naknade za obnovljive izvore energije.⁴¹

⁴¹ Hrvatska narodna banka, Godišnje izvješće 2017., Zagreb, 2018., str. 27-28., dostupno na: <https://www.hnb.hr/documents/20182/2521149/h-gi-2017.pdf/ebe924fb-b40b-49cb-8ca2-1f03204f7e03>

5. PHILLIPSOVA KRIVULJA I OKUNOV ZAKON

Phillipsova krivulja i Okunov zakon usko su povezani s temom koja se obrađuje unutar ovoga rada. Navedeni modeli su vrlo teoretski i konceptualno važni za tematiku rada zbog toga što Phillipsova krivulja predstavlja odnos između nezaposlenosti i inflacije, a Okunov zakon objašnjava odnos između nezaposlenosti i BDP-a. Fenomen Phillipsove krivulje podrazumijeva da visoka nezaposlenost ima ograničen efekt u smanjivanju inflacije, dok niska razina nezaposlenosti može imati znatno jači efekt na istu.⁴² Okunov zakon, samo je dio empirijske makroekonomije koje zajedno sa svim vezanim tematikama kao što je Phillipsova krivulja pruža mogućnost dati jasne odgovore za potencijalne probleme u hrvatskom gospodarstvu. Problematika odnosa između outputa i nezaposlenosti u Hrvatskoj je od iznimne važnosti znajući da je BDP Hrvatske daleko ispod svoje potencijalne razine te da je visoka stopa nezaposlenosti duboko ukorijenjena u okvire hrvatskog tržišta rada.⁴³ Nadalje, cilj svakog gospodarstva jest doseći što viši gospodarski rast i što nižu stopu nezaposlenosti, pri tome ne stvarajući inflatorne pritiske.⁴⁴ Varijable koje se odnose na ova dva fenomena od velike su važnosti za svako gospodarstvo. Bruto domaći proizvod, nezaposlenost i inflacija su neizostavan dio svakog proučavanja ekonomije. U nastavku teksta u kratko su obrađene obje tematike te navedena mišljenja odabranih znanstvenika koja su se bavila istraživanjem navedenim fenomenima.

5.1. Phillipsova krivulja

Alban William Phillips 1958. godine nacrtao je dijagram koji je prikazivao stopu inflacije i stopu nezaposlenosti u Ujedinjenom Kraljevstvu (UK) za svaku promatranu godinu od 1861. godine do 1957. godine. Došao je do jasnog dokaza koji ukazuje na negativan odnos između inflacije i nezaposlenosti, odnosno – kada je nezaposlenost bila niska, inflacija je bila visoka, te kada je nezaposlenost bila visoka, inflacija je bila niska. Dvije godine kasnije, Robert Solow i Paul Samuelson su kopirali Phillipsovu vježbu na primjeru Sjedinjenih Američkih Država (SAD) koristeći podatke od 1990.

⁴² D.Tomić, Testiranje Okunovog zakona u hrvatskom gospodarstvu, Magistarski rad, Sveučilište Jurja Dobrile u Puli, Odjel za ekonomiju i turizam „dr.MijoMirković“, Pula, 2009, str. 32

⁴³ Ibidem, str. 1

⁴⁴ Ibidem, str. 8

godine do 1960. godine. Izuzimajući razdoblje visoke nezaposlenosti tijekom 1930-ih godina, činili se da također postoji negativan odnos između nezaposlenosti i inflacije u SAD-u. Upravo je ta relacija ubrzo došla u središte makroekonomskog razmišljanja i makroekonomske politike.

Phillipsova krivulja je zapravo krivulja koja pokazuje ovisnost stope inflacije, plaća i stope nezaposlenosti. Isto tako, povezuje porast cijena ili porast cijena i plaća s porastom nezaposlenosti. Krivulja u suštini prikazuje klasičan izbor s kojima se susreću kreatori ekonomske politike, odnosno biraju dvije opcije koje su usko povezane te izbor bilo koje donosi i pozitivne i negativne posljedice. A.W. Phillips je svoju krivulju predstavio u radu u kojemu je razmatrao odnos zaposlenosti, inflacije i rasta 1962. godine. Danas se krivulja više ne smatra relevantnom, što je dokazala teorija te iskustvo posljednjih desetljeća. Phillipsova krivulja spaja kombinacije stopa inflacije i nezaposlenosti koje su uzrokovane promjenama krivulje agregatne potražnje, a posljedica su kretanja gospodarstva uzduž krivulje agregatne ponude koje u ravnoteži rezultiraju određenim razinama cijena i outputa, odnosno zaposlenosti. Upravo zbog toga Phillipsova krivulja može koristiti za izbor željene inflacije i nezaposlenosti, a kako mjere fiskalne i monetarne politike utječu na promjene agregatne potražnje upravo one omogućuju kretanje gospodarstva po Phillipsovoj krivulji što rezultira određenim stopama inflacije i nezaposlenosti.⁴⁵

Kad je proizvodnja visoka, a nezaposlenost niska nadnice i cijene brže rastu. Razlog je tome što radnici, odnosno sindikati vrše neku vrstu pritiska za povećanje plaća jer se novi poslovi otvaraju te se povećava obujam posla, a s druge strane poduzeća imaju mogućnost povećati cijene proizvoda kada je potražnja visoka, a prodaja sigurna.

Izvorna Phillipsova krivulja 1960-ih doživjela je potvrdu u stvarnom životu. Zadovoljavajući izbor između stope inflacije i nezaposlenosti na predvidiv način, kao posljedica mjera ekonomske politike, bio je moguć u Sjedinjenim Američkim Državama. Tada, Phillipsova krivulja bila je stabilna, a inflacija blaga kao i u prethodnom desetljeću. Međutim, sedamdesetih i osamdesetih godina prošlog

⁴⁵ Đ. Benić, *Povijest razvoja teorije o odnosu između inflacije i nezaposlenosti*, EKONOMSKA MISAO i PRAKSA DBK. GOD XXIII. (2014.) Br.2. str. 413, dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=193320

stoljeća, uslijed naftnih šokova, situacija se u potpunosti promijenila. Došlo je do rasta inflacije, a kontrakcijska monetarna i fiskalna politika dovele su do rasta nezaposlenosti. Izvorna se Phillipsova krivulja pokazala neodgovarajućom osnovom za vođenje ekonomske politike, iako su istraživanja pokazivala da i dalje u kratkom roku postoji obratno uzajaman odnos između inflacije i nezaposlenosti.⁴⁶

Zahvaljujući dostupnim i sve sofisticiranijim statističkim alatima koji su danas postali integralnim dijelom svake ozbiljne kvantitativne analize, razni istraživači su došli do različitih saznanja i svaki od njih je na određeni način pridonio riznici spoznaje inflacijskog procesa u Hrvatskoj. Radovi na temu inflacije posljednjih 15-ak godina raste jer monetarne vlasti mnogih zemalja zaključile su da je dostizanje i održavanje stabilnosti cijena, pri čemu se misli na nisku stabilnu stopu inflacije, glavni doprinos koji monetarna politika može dati ekonomskom rastu. Neke od značajnih analiza navedene su u nastavku rada a prilikom analize istih korištene su različite metode i pristupi.

Payne (2002.), Botrić i Cota (2006.) analizirali su inflaciju *unrestricted* VAR modelom (vektorski autoregresijski model) za različita vremenska razdoblja te su rezultati uspoređivani s onima koji su dobiveni SVAR modelom (strukturni vektorski autoregresijski model). Rezultati dobiveni procjenom VAR modela kod Payne upućuju na pozitivnu empirijsku povezanost između indeksa cijena na malo, neto nominalnih plaća po zaposlenom, stope promjene novčane mase i nominalnog efektivnog tečaja. Isto tako, otkriva nepostojanje inflacijske inercije što nije u skladu s rezultatima ostalih istraživanja, no značajno je naglasiti da je analiza uključivala razdoblje od 1992. godine do 1999. godine, tj. u analizu je uključeno hiperinflacijsko razdoblje te bi se upravo zbog toga konačni zaključci trebali postavljati uz mjeru opreza. Revidirajući razmatrano razdoblje Botrić i Cota pronalaze kako utjecaj rasta nominalnih plaća izgubio na važnosti, rast monetarnih agregata nema velik i značajan utjecaj, te su isti zaključci došli i koristeći se SVAR metodom. Isto tako, upozoravaju na postojanje inflacijske inercije u razmatranom razdoblju od 1998. godine do 2006. godine. Rezultati obje analiza upućuju na eksternu ranjivost Hrvatske, VAR kroz utjecaj tečaja na cijene, dok SVAR utvrđuje pozitivan odgovor

⁴⁶ ibidem, str. 414.

cijena u Hrvatskoj na šokove uvjeta razmjene i šokove agregatne ponude. Družić, Tica i Mamić (2006.) analiziraju primjenjivost adaptivnim očekivanjima proširene Phillipsove krivulja na godišnjoj razini u razdoblju od 1962. godine do 2004. godine te ne otkrivaju signifikantnu vezu između inflacije i tržišta rada. No međutim, otkrivaju osjetljivost inflacije na tečaj njemačke marke i postojanje inflacijske inercije. Malašević (2009.) je analizirao inflaciju pomoću kointegracijskog pristupa. Primjena kointegracije i vektorskog modela korekcije grešaka identificirala je postojanje značajnog i dugoročnog odnosa od 1994. godine do 2006. godine između plaće, inflacije i tečaja, ali ne i ponude novca. Rezultati istraživanja ukazivali su na zaključak kako je potrebno otprilike 7 mjeseci da bi promjene inflacije vratile razinu cijena njihovoj dugoročnoj ravnoteži te isto vrijedi i za plaće. S druge strane, tečaju je potrebno oko 3,5 godina da razinu cijena vrati u ravnotežu. Isto tako, kratkoročni utjecaji inflacije iz prethodnog razdoblja su značajni.⁴⁷

Uspjesi i neuspjesi Phillipsove krivulja su se pokazali kao bitan element razvoja makroekonomske znanosti, pri čemu je trade-off između nezaposlenosti i inflacije bitan za razumijevanje učinaka monetarne politike, ali i ostalih ekonomskih politika koje utječu na agregatnu potražnju. Phillipsova krivulja, ali i njezina kasnija proširenja, postala je ključni dio standardnih keynesijanskih modela i osnova za proučavanje kratkoročnog kretanja između nezaposlenosti i inflacije.⁴⁸

⁴⁷ O. Nadoveza, J.Šimurina, *Prognoziranje inflacije - primjer Hrvatske*, Zbornik Ekonomskog fakulteta u Zagrebu, godina 8, 2010., br.2, str. 83.-83., dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=105344

⁴⁸ S.Sharma, D.Tomić, op.cit., str.95

5.2. Okunov zakon

Arthur M. Okun (1928.-1980.), američki ekonomist, član Vijeća ekonomskih savjetnika predsjednika SAD-a, te profesor ekonomije na Sveučilištu Yale, tvorac je tzv. Okunovog zakona. Okun, pristalica Keynesove ekonomske teorije, smatrao je fiskalnu politiku boljim instrumentom utjecaja na ekonomsku politiku zemlje nego monetarnu politiku. Sredinom 60-ih godina Sjedinjene Američke Države su se suočavale s recesijom u gospodarstvu. Kako bi se recesija riješila, predsjedniku je predloženo smanjiti porezno opterećenje građana kako bi se potaknula potrošnja. Tijekom Okunovog predsjedanja Vijećem Ekonomskih savjetnika, država je stvorila ogroman proračunski deficit posuđivanjem novaca za rat u Vijetnamu. Nakon napuštanja mjesta predsjednika Vijeća Ekonomskih savjetnika, Okun se zapošljava u Brookings Insitutiton gdje je istraživao i analizirao trendove u ekonomiji.⁴⁹ Empirijski utvrđena povezanost nacionalnog outputa i nezaposlenosti koja se očituje kroz Okunov koeficijent pripada okvirima monoekonomije time što se smatra univerzalnom istinom koja vrijedi za sve zemlje i sve gospodarske uvjete. Iako okvirno polazi od keynesijanske istine, Okunov zakon prihvaćen je kao dio ortodoksne ekonomije i neo-klasične sinteze te, ponesen mainstream pozadinom, postaje jednim od najzanimljivijih znanstvenih tematika 20. stoljeća.⁵⁰

Nadalje, u periodu recesije, output i nezaposlenost obično su visoki, dok je u periodu procvata ekonomije bruto društveni proizvod blizu ili iznad potencijalnog, zaposlenost je visoka, te s druge strane, nezaposlenost se smanjuje. Postoji li veza između inflacije i nezaposlenosti dao je upravo ekonomist Arthur Okun. Prema Okunovom zakonu, na svakih 2% pada bruto društvenog proizvoda u odnosu na potencijalni bruto nacionalni proizvod, stopa nezaposlenosti povećava se za 1%. Na primjer, ako bruto nacionalni proizvod padne sa 100% na 98%, nezaposlenost će porasti sa prvobitnih 6% na 7%. Do recesije dolazi kada se agregatna potražnja smanjuje u odnosu na agregatnu ponudu.⁵¹

⁴⁹ Encyclopedia Britannica, dostupno na: <https://www.britannica.com/biography/Arthur-M-Okun>

⁵⁰ D. Tomić, Testiranje Okunova zakona u hrvatskom gospodarstvu, Magistarski rad, Sveučilište Jurja Dobrile u Puli, Odjel za ekonomiju i turizam „dr. Mijo Mirković“, Pula, 2009., str. 49

⁵¹ nepoznat autor, *Okunov zakon i Phillipsova krivulja*, dostupno na: <https://www.coursehero.com/file/phfh6m/To-je-slu%C4%8Daj-oporezivanja-mimo-zakona-%C5%A1to-je-mnoge-zemlje-navelo-da-na/r>

Okun je najpoznatiji po njegovom istraživanju provedenom na primjeru gospodarstva Sjedinjenih Američkih Država gdje govori da rast nezaposlenosti od 1% smanjuje BDP za 3%. Tijekom burnih 70-ih kad je gospodarstvo prolazilo kroz stagflaciju, pravilo više nije vrijedilo. Do kraja života Okun je tražio načina da smanji inflaciju izbjegavajući recesiju. Također je formulirao univerzalnu definiciju za recesiju kao dva uzastopna tromjesečja tijekom kojeg se BDP smanjuje.⁵² „*Potential GNP: Its Measurement and Significance*“, Arthura Okuna (1962.) otvorilo je pitanje koliko outputa može jedno gospodarstvo proizvesti u uvjetima pune zaposlenosti?⁵³ Bruto domaći proizvod predstavlja jednu od osnovnih makroekonomskih varijabli, uz nju se također nalaze štednja, investicije, razina bogatstva, inflacija, kamatna stopa i nezaposlenost. Ove makroekonomske varijable služe za postizanje odnosno dostizanje općih ciljeva makroekonomske politike a to su: održavanje stabilnosti cijena, visoka i rastuća razina outputa te visoka zaposlenost. Okun kroz svoj rad pokazuje upravo vezu između tržišta dobara i tržišta rada povezujući kratkoročna kretanja outputa, odnosno realnog BDP-a i promjene nezaposlenosti.⁵⁴ Nadalje, razdoblja slabijeg gospodarskog rasta su odgovorna za rast stope nezaposlenosti. Razdoblja ekspanzivnog rasta stvaraju očekivanja prema opadanju stope nezaposlenosti, odnosno prema rastu zaposlenosti koji je praćen rastom bruto domaćeg proizvoda. Međuzavisnost različitih procesa i stanja u okvirima adaptivnih očekivanja, promjene stope rasta nacionalnog proizvoda, strukture tržišta rada čine znatno složenijim razumijevanje gospodarskog rasta. Potrebno je napomenuti kako nije dovoljno održavati istu razinu efektivnog dohotka kako bi se osigurala neprekidna puna zaposlenost, već je ta veza cilj koji se analizira kroz problematiku potencijalnog outputa koju je razvio Okun. Okunov zakon linearno veže potencijalni i realni bruto domaći proizvod i stopu nezaposlenosti. Prema njemu, kada stopa rasta realnog proizvoda prelazi stopu rasta potencijalnog proizvoda, stopa nezaposlenosti pada. Suprotno tome, kada je stopa rasta realnog proizvoda niža od stope rasta potencijalnog proizvoda, stopa nezaposlenosti raste. Analizirano na ovaj način prikazan odnos između stope rasta bruto domaćeg proizvoda i stope nezaposlenosti

⁵² Đ. Benić, *Makroekonomija*, Školska knjiga, 2016., str. 295.

⁵³ A. M. Okun, *Potential GNP: Its Measurement and Significance*, Cowless Foundation, Yale University, 1962. Dostupno na: <https://mileskorak.files.wordpress.com/2016/01/okun-potential-gnp-its-measurement-and-significance-p0190.pdf>

⁵⁴ Đ. Benić, op.cit., str. 294.

je jedna od najkonzistentnijih relacija u makroekonomskoj teoriji i stvarnosti, a to potvrđuju i empirijska istraživanja posljednjih pedesetak godina.⁵⁵

Osnovni smisao Okunovog zakona je da dohodak mora rasti brže od ukupne produktivnosti i rasta populacije kako bi se u konačnici nezaposlenost smanjivala.⁵⁶ Okunov empirijski odnos proizašao je iz jednostavnog opažanja da je za proizvodnju veće količine dobara i usluga u okvirima nekog gospodarstva neophodna i veća količina radne snage. Više rada moguće je ostvariti kroz zapošljavanje nove radne snage ili produljenja radnih sati postojećih zaposlenika. Okun je stoga uzeo nezaposlenost kao varijablu koja najbolje opisuje radnu snagu.⁵⁷ Nadalje, procjena Okunovog zakona u obliku tzv. Okunovog koeficijenta pokazuje mjeru odgovornosti nezaposlenosti u rastu bruto domaćeg proizvoda i stoga je važan indikator troška nezaposlenosti u terminima outputa. Sagledavajući odnose između varijabli, Okunov koeficijent, kao parametar, može dati odgovor kolika je jaka veza između varijabli, ali i dati odgovor tipa koja stopa outputa na godišnjoj razini neće stvarati nezaposlenost.⁵⁸

⁵⁵S.Sharma, D.Tomić, op.cit., str. 91

⁵⁶ibidem., str. 92

⁵⁷D.Tomić, op.cit, str. 15

⁵⁸Ibidem, str. 7


6. METODOLOŠKI PRISTUP ODABRANIH VARIJABLI

Varijable koje će se testirati su broj zaposlenih, nominalne bruto plaće, realne bruto plaće te indeks temeljne inflacije (u daljnjem tekstu: temeljna inflacija). Istraživanje se temelji na kvartalnim podacima prikupljenim na stranici HNB-a, te procjeni regresijskog modela pomoću ekonometrijskog programa Gretl. Svi podaci su desezonirani. Razdoblje istraživanja je od 1999:3 do 2016:4. Također, u radu su izdvojeni dijelovi unutar Gretl programa koji su potrebni za analiziranje, a cjelovite tablice nalaze se u Prilogu na kraju rada.

Nadalje, varijabla broj zaposlenih za analizu je odabran zbog toga što upravo rast ili pad zaposlenih je vrlo važan parametar, u nekim sferama čak i važniji od nezaposlenosti. To znači da analize o nezaposlenosti treba uzimati i koristiti s rezervom jer je, analizirajući trenutno stanje u Hrvatskoj, pad upravo tog pokazatelja najvećim dijelom uzrokovan odlaskom radno aktivnog stanovništva u inozemstvo. Varijabla realne i nominalne bruto plaće se analiziraju iz razloga što bruto plaće prikazuju stvarno stanje isplaćenih plaća, odnosno zaposlenici kojima se plaće isplaćuju, u većini slučajeva imaju uvid u neto plaće te vrlo često ne uzimaju u obzir koliko je zapravo njihov poslodavac platio njihov rad koji se očituje u bruto iznosima. Varijabla temeljne inflacije odabrana je iz razloga što isključuje promjene cijena energenata i poljoprivrednih proizvoda. Drugim riječima, svrha usmjerivanja na temeljnu inflaciju je da se iz inflacije isključe nemonetarne determinante inflacije. Isto tako, razlog je mišljenje i izjava guvernera HNB-a Borisa Vujčića da mjera kretanja cijena u privredi je vrlo važna za vođenje monetarne politike jer se radi o mjeri kretanja razine cijena koja ovisi o ponudi i potražnji, zbog toga što se isključuju izrazito volatilne cijene poput poljoprivrednih prehrambenih proizvoda, kao i one koje su regulirane, i ona pomaže u raspoznavanju jesu li promjene kretanja potrošačkih cijena uzrokovane kratkoročnim poremećajima ili postoje određeni dugoročni trendovi. Također, guverner tvrdi da se samo na temeljnu inflaciju gleda na način na čega bi se trebalo reagirati.

6.1. Kretanje odabranih varijabli

Grafikon 3. *Kretanje varijabli: broj zaposlenih, nominalne bruto plaće, realne bruto plaće, temeljna inflacija (indeks) od 1999. do 2016. godine u RH*

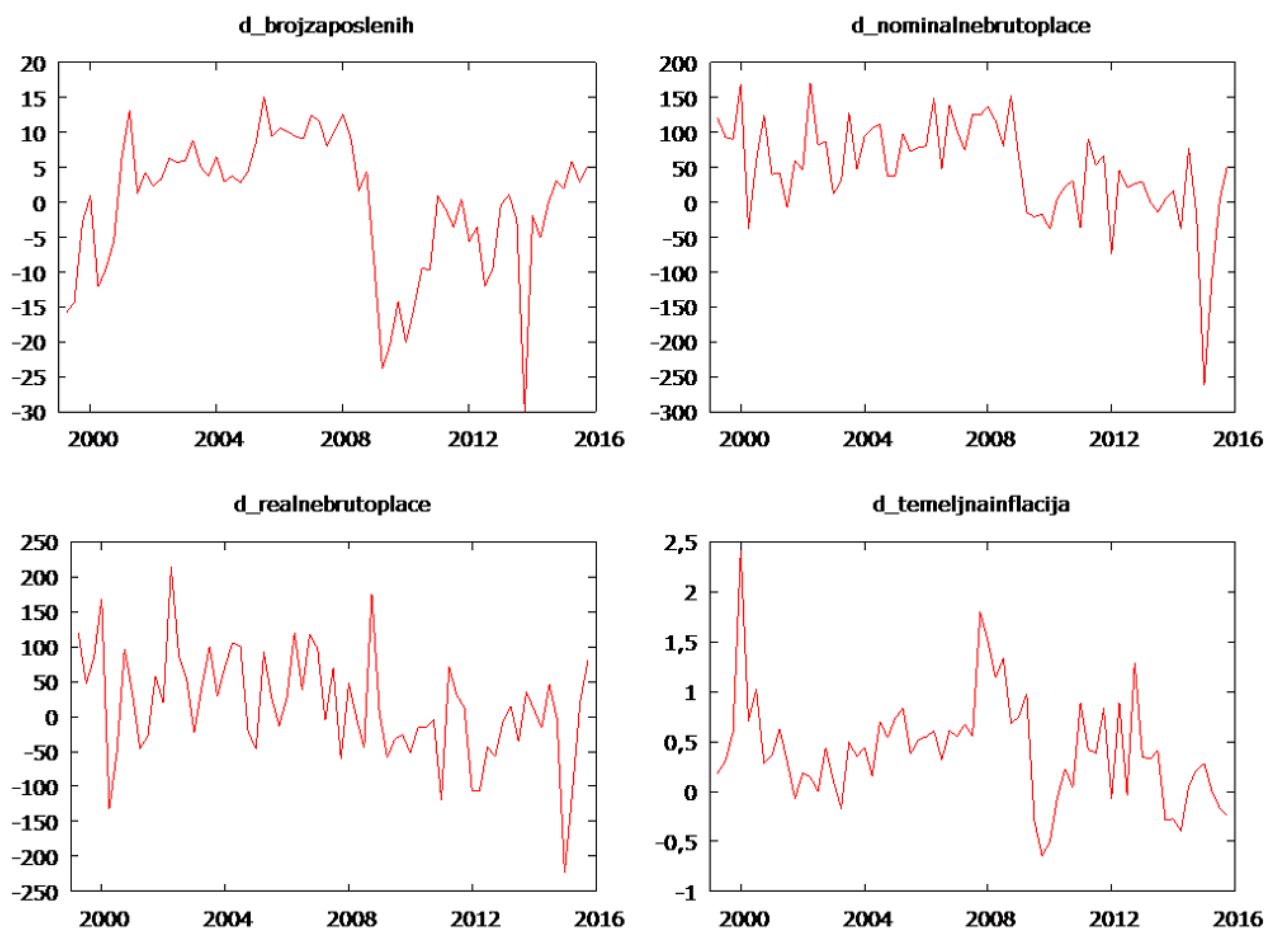


Izvor: izrada autora u Gretl-u

U Grafikonu 3. vidljiv je trend rasta unutar tri varijable – realne bruto plaće, nominalne bruto plaće i temeljna inflacija, dok broj zaposlenih do 2008. godine raste i početkom financijske krize opada.

U daljnjoj analizi potrebno je utvrditi je li trend značajan i vraćaju li se krivulje u nulu. Ako se krivulje vraćaju u nulu odnosno konvergiraju prema nuli radi se o stacionarnim procesima, a ako krivulje imaju tendenciju rasta i pada radi se o nestacionarnim procesima.

Grafikon 4. Kretanje varijabli dodavanjem prve diferencije od 1999. do 2016. godine u RH



Izvor: izrada autora u Gretl-u

Dodavanjem prvih diferencija može se uočiti da se varijable relativno vraćaju, odnosno konvergiraju prema nuli i trebalo bi se raditi o stacionarnim procesima. Za bolju analizu potrebno je provesti Dickey-Fuller test kako bi se postavljena hipoteza potvrdila ili odbacila.

Slika 1. Dickey-fuller test za varijablu broj zaposlenih

Augmented Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 (T = 66)
Dependent variable: d_brojzaposlenih

	coefficient	std. error	t-ratio	p-value
const	30,8439	19,7508	1,562	0,1235
brojzaposlenih_1	-0,0199939	0,0136297	-1,467	0,8409
d_brojzaposlen~1	0,703236	0,0876720	8,021	3,64e-011 ***
time	-0,0277985	0,0461580	-0,6022	0,5492

Izvor: izrada autora u Gretl-u

Iz Dickey-Fuler testa za varijablu broj zaposlenih vidljivo je da trend nije značajan u procesima budući da je t-vrijednost manja od 2 (t-vrijednost = 0,6022) i radi se o stacionarnom procesu. Također, p-vrijednost je veća od 0,05 (p-vrijednost = 0,5492) što ukazuje da značajnost testa ne možemo odbaciti. Diferencirana varijabla broj zaposlenih putem p-vrijednosti također ukazuju na stacionaran proces jer je p-vrijednost manja od 0,05.

Slika 2. Dickey-fuller test za varijablu nominalne bruto plaće

Dickey-Fuller regression				
OLS, using observations 1999:2-2015:4 (T = 67)				
Dependent variable: d_nominalnebrutoplace				
	coefficient	std. error	t-ratio	p-value
const	-50,4320	102,546	-0,4918	0,6245
nominalnebruto~_1	0,0355206	0,0221745	1,602	1,0000
time	-3,89076	1,36991	-2,840	0,0060 ***

Izvor: izrada autora u Gretl-u

Iz Dickey-Fuler testa za varijablu nominalne bruto plaće vidljivo je da je trend značajan u procesima budući da je t-vrijednost veća od 2 (t-vrijednost = 2,840) i radi se o nestacionarnom procesu. Također, p-vrijednost je manja od 0,05 (p-vrijednost = 0,0060) što ukazuje da značajnost testa možemo odbaciti. Potrebno je uzeti prvu diferenciju varijable koja je nestacionarna kako bi stacionirali proces ukoliko se radi o I(1) procesu. Ukoliko se radi o I(1) procesu onda se proces detrendiranjem može stacionirati.

Slika 3. Stacioniranje varijable nominalne bruto plaće pomoću Dicky-fuller testa

Dickey-Fuller regression				
OLS, using observations 1999:3-2015:4 (T = 66)				
Dependent variable: d_d_nominalnebrutoplace				
	coefficient	std. error	t-ratio	p-value
const	26,6968	9,62244	2,774	0,0072 ***
d_nominalnebru~_1	-0,561923	0,111290	-5,049	7,75e-05 ***

Izvor: izrada autora u Gretl-u

Izbacili smo trend iz testa i može se zaključiti da je dobiveni proces stacionaran jer je p-vrijednost manja od 0,05. Radi se o I(1) procesu, odnosno procesu koji moramo jednom diferencirati kako bi ga stacionirali.

Slika 4. Dickey-fuller test za varijablu realne bruto plaće

Augmented Dickey-Fuller regression				
OLS, using observations 1999:4-2015:4 (T = 65)				
Dependent variable: d_realnebrutoplace				
	coefficient	std. error	t-ratio	p-value
const	98,2856	182,985	0,5371	0,5932
realnebrutopla~_1	-0,00316594	0,0282362	-0,1121	0,9947
d_realnebrutop~_1	0,110127	0,131455	0,8378	0,4055
d_realnebrutop~_2	-0,219175	0,132800	-1,650	0,1041
time	-1,65372	0,825005	-2,004	0,0495 **

Izvor: izrada autora u Gretl-u

Iz Dickey-Fuler testa za varijablu realne bruto plaće vidljivo je da je t-vrijednost na granici značajnosti ali može se zaključiti da je trend značajan u procesima budući da je t-vrijednost veća od 2 (t-vrijednost = 2,004) i radi se o nestacionarnom procesu. Također, p-vrijednost je manja od 0,05 (p-vrijednost = 0,0495) što ukazuje da značajnost testa možemo odbaciti.

Potrebno je uzeti prvu diferenciju varijable koja je nestacionarna kako bi stacionirali proces ukoliko se radi o I(1) procesu. Ukoliko se radi o I(1) procesu onda se proces detrendiranjem može stacionirati kao i u slučaju prethodne varijable.

Slika 5. Stacioniranje varijable realne bruto plaće pomoću Dicky-fuller testa

Dickey-Fuller regression				
OLS, using observations 1999:3-2015:4 (T = 66)				
Dependent variable: d_d_realnebrutoplace				
	coefficient	std. error	t-ratio	p-value
const	11,1163	9,44487	1,177	0,2436
d_realnebrutop~_1	-0,772150	0,120626	-6,401	5,62e-07 ***

Izvor: izrada autora u Gretl-u

Izbacili smo trend iz testa i može se zaključiti da je dobiveni proces stacionaran jer je p-vrijednost manja od 0,05. Radi se o $I(1)$ procesu, odnosno procesu koji moramo jednom diferencirati kako bi ga stacionirali.

Slika 6. *Dickey-fuller test za varijablu temeljna inflacija*

Augmented Dickey-Fuller regression					
OLS, using observations 1999:4-2015:4 (T = 65)					
Dependent variable: d_temeljnainflacija					
	coefficient	std. error	t-ratio	p-value	
const	5,31609	2,62449	2,026	0,0473	**
temeljnainflac~_1	-0,0703677	0,0371341	-1,895	0,06571	
d_temeljnainfl~_1	0,328282	0,122557	2,679	0,0095	***
d_temeljnainfl~_2	0,328194	0,127006	2,584	0,0122	**
time	0,0292105	0,0181196	1,612	0,1122	

Izvor: izrada autora u Gretl-u

Iz Dickey-Fuler testa za varijablu temeljna inflacija vidljivo je da trend nije značajan u procesima budući da je t-vrijednost manja od 2 (t-vrijednost = 1,612) i radi se o stacionarnom procesu. Također, p-vrijednost je veća od 0,05 (p-vrijednost = 0,1122) što ukazuje da značajnost testa ne možemo odbaciti. Diferencirana varijabla temeljna inflacija putem p-vrijednosti također ukazuju na stacionaran proces jer je p-vrijednost manja od 0,05.

6.2. Odabir modela za analizu rezultata

Model korišten za analizu utjecaja između odabranih varijabli u Hrvatskoj je VAR model (*vector autoregression*), odnosno vektorska autoregresija. VAR modeli predstavljaju osnovu za definiranje statističkih koncepata u ekonometrijskim istraživanjima, odnosno istraživanjima uzročnosti i kointegracije. Ekonomska primjena VAR modela sastoji se u analizi efekata ekonomske politike na bazi korištenja metoda dekompozicije prognostičke greške i impulsnih utjecaja. Faze u primjeni VAR modela su specifikacija i ocjena parametara, određivanje impulsnih utjecaja, dekompozicija varijance prognostičke greške. Testiranja u VAR modelu odnose se na test autokorelacije, heteroskedastičnosti, normalnosti distribucije reziduala te na određivanje broja vremenskih pomaka. Nadalje, prije konstruiranja modela određen je broj vremenskih pomaka modela što je prikazano u nastavku.

Slika 7. Broj vremenskih pomaka

VAR system, maximum lag order 4					
The asterisks below indicate the best (that is, minimized) values of the respective information criteria, AIC = Akaike criterion, BIC = Schwarz Bayesian criterion and HQC = Hannan-Quinn criterion.					
lags	loglik	p(LR)	AIC	BIC	HQC
1	-906,91292		28,966029	29,640680*	29,231808
2	-876,58302	0,00000	28,518219	29,732591	28,996622*
3	-859,84958	0,00641	28,495299*	30,249392	29,186325
4	-846,80332	0,05274	28,587604	30,881417	29,491253

Izvor: izrada autora u Gretl-u

Test se provodi u četiri vremenska pomaka i cilj je izabrati pravilan broj vremenskih pomaka za autoregresivni model. Iz dobivenih rezultata može se zaključiti da Akaike kriterij ukazuje na tri vremenska pomaka, Schwartzov kriterij ukazuje na jedan vremenski pomak dok Hannan-Quinnov kriterij ukazuje na dva vremenska pomaka. U relevantnoj ekonometrijskoj literaturi postoje slaganja koja govore u prilog superiornosti Hannan-Quinn kriterija u odnosu na ostale kriterije pa će se za analizu uzeti da model ima dva vremenska pomaka.⁵⁹

AIC = 28,495299

BIC = 29,640680

HQC = 28,996622

VAR model iz Gretl programa nalazi se u Prilogu (*Prilog 7.*)

6.3. Ocjena kvalitete modela

Nakon postavljenog modela potrebno je ocijeniti kvalitetu modela. Pri ocjeni kvalitete modela promatra se korigirani koeficijent determinacije (Adjusted R-squared) koji ukazuje da je objašnjeno 98% (broj zaposlenih, realne bruto plaće) i 99% (nominalne bruto plaće, temeljna inflacija) varijacije.

⁵⁹ D. Tomić (2014.) Konkurentnost, ekonomski rat i blagostanje: Može li Hrvatska tražiti izlaz iz „gospodarske agonije“ kroz izvoz?, Zbornik radova, Sveučilište J.J. Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, str. 291., dostupno na: http://www.efos.unios.hr/konkurentnost-ekonomski-rast-i-blagostanje/wp-content/uploads/sites/378/2014/10/Zbornik_IFK_2014_konacni.pdf

U sljedećem koraku potrebno je provesti test autokorelacije i heteroskedastičnosti kako bi se utvrdila ispravnost modela, odnosno potrebno je testirati je li postavljeni model ispravan model.

Slika 8. *Test autokorelacije u VAR modelu*

Equation 1: Ljung-Box Q' = 1,16526 with p-value = P(Chi-square(4) > 1,16526) =	0,884
Equation 2: Ljung-Box Q' = 4,86684 with p-value = P(Chi-square(4) > 4,86684) =	0,301
Equation 3: Ljung-Box Q' = 4,69753 with p-value = P(Chi-square(4) > 4,69753) =	0,32
Equation 4: Ljung-Box Q' = 5,11171 with p-value = P(Chi-square(4) > 5,11171) =	0,276

Izvor: izrada autora u Gretl-u

Autokorelacija označava korelaciju između članova niza opažanja poredanih po vremenu ili prostoru u vremenskom nizu ili u vremenskom presjeku. Pretpostavka je da autokorelacije nema. Prema Ljung-Box Q statistici vidljivo je da u modelu nije prisutna autokorelacija jer je p-vrijednost veća od 0,05 što znači da nemamo problema sa autokorelacijom te test autokorelacije upućuje na ispravnost modela. Testiranje heteroskedastičnosti predstavlja test koji pretpostavlja konstantu varijancu slučajne greške koja je jednaka za sva opažanja. P-vrijednosti svih varijabli veće su od 0,05 što ukazuje da model nema problema sa heteroskedastičnošću, a testiranje heteroskedastičnosti u VAR modelu nalazi se u Prilogu.

Unatoč tome da model nema problema, odnosno da autokorelacija i heteroskedastičnost nisu prisutne može se zaključiti da je odabrani VAR model ispravan model.

Nadalje, u nastavku su postavljene funkcije za sve četiri promatrane varijable.

Funkcija prve varijable (broj zaposlenih) glasi:

$$\text{BROJ ZAPOSLENIH} = 0,6621 + 1,5738\text{BR.ZAPt-1} + 0,0765\text{NOM.BPt-1} - 0,0767\text{REAL.BPt-1} - 0,2178\text{TEM.INFt-1} - 0,6092\text{BR.ZAPt-2} + 0,0430\text{NOM.BPt-2} + 0,0009\text{REAL.BPt-2} + 0,0432\text{TEM.INFt-2}$$

Funkcija druge varijable (nominalne bruto plaće) glasi:

$$\text{NOMINALNE BRUTO PLAĆE} = 1,6558 + 0,2429\text{BR.ZAPt-1} + 1,5674\text{NOM.BPt-1} - 0,6766\text{REAL.BPt-1} - 0,7861\text{TEM.INFt-1} + 0,0101\text{BR.ZAPt-2} - 0,1565\text{NOM.BPt-2} + 0,1475\text{REAL.BPt-2} + 0,2482\text{TEM.INFt-2}$$

Bitno je za naglasiti da varijable temeljna inflacija i realne bruto plaće upućuju na značajnost parametara a to je vidljivo prema njihovoj p-vrijednosti koja je manja od 0,05. Drugim riječima, temeljna inflacija i realne bruto plaće utječu na nominalne bruto plaće.

Funkcija treće varijable (realne bruto plaće) glasi:

$$\text{REALNE BRUTO PLAĆE} = 2,0518 + 0,3088\text{BR.ZAPt-1} + 0,4698\text{NOM.BPt-1} + 0,4413\text{REAL.BPt-1} - 0,9113\text{TEM.INFt-1} - 0,0439\text{BR.ZAPt-2} - 0,0212\text{NOM.BPt-2} - 0,0628\text{REAL.BPt-2} + 0,3739\text{TEM.INFt-2}$$

Temeljna inflacija upućuje na značajnost parametra na temelju p-vrijednosti koja je manja od 0,05 (p-vrijednost = 0.0014), odnosno temeljna inflacija utječe na realne bruto plaće.

Funkcija četvrte varijable (temeljna inflacija) glasi:

$$\text{TEMELJNA INFLACIJA} = 1,0679 + 0,0178\text{BR.ZAPt-1} + 0,1569\text{NOM.BPt-1} - 0,2192\text{REAL.BPt-1} + 1,0772\text{TEM.INFt-1} + 0,0648\text{BR.ZAPt-2} + 0,1097\text{NOM.BPt-2} - 0,0559\text{REAL.BPt-2} - 0,4275\text{TEM.INFt-2}$$

Nadalje, postavljanjem funkcija za sve četiri promatrane varijable može se zaključiti da relacije sugeriraju očekivane rezultata.


6.4. Testiranje utjecaja odabranih varijabli

U nastavku testirat će se utjecaji promatranih varijabli kroz impulsne funkcije, uzročnost u Grangerovom smislu te doprinos varijabli na prognostičku grešku kroz određeno razdoblje.

6.4.1. Prikaz utjecaja varijabli kroz 30 godina

Kroz impulsne funkcije prikazat će se postoje li utjecaji među promatranim varijablama i kroz koliko godina, odnosno postoji li dugoročni utjecaj.


Slika 9. *Utjecaj varijabli na broj zaposlenih kroz 30 godina*



Izvor: izračun autora u Gretl-u

Iz grafikona je vidljivo (Slika 9.) da nominalne i realne bruto plaće te temeljna inflacija ne utječu na broj zaposlenih. Varijabla Broj zaposlenih se nakon petnaestak godina vraća u prvobitno stanje, odnosno u ravnotežu.


Slika 10. *Utjecaj varijabli na nominalne bruto plaće kroz 30 godina*



Izvor: izračun autora u Gretl-u

Iz grafikona je vidljivo (Slika 10.) da broj zaposlenih utječe na nominalne bruto plaće dok realne bruto plaće i inflacija ne utječu na nominalne bruto plaće.

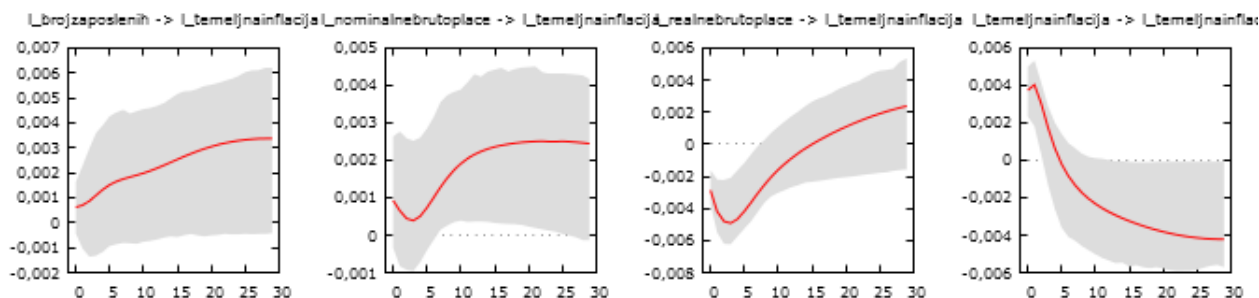
Slika 11. *Utjecaj varijabli na Realne bruto plaće kroz 30 godina*



Izvor: izračun autora u Gretl-u

Iz grafikona je vidljivo da broj zaposlenih i nominalne bruto plaće utječu na realne bruto plaće dok temeljna inflacija ne utječe na broj zaposlenih.

Slika 12. *Utjecaj varijabli na temeljnu inflaciju kroz 30 godina*



Izvor: izračun autora u Gretl-u

Iz grafikona je vidljivo da niti jedna varijabla značajno ne utječe na temeljnu inflaciju jer niti jedna varijabla, u ovome slučaju, ne kreće od nule. Drugim riječima, utjecaji su minimalni i ekonomski irelevantni u interpretativnom smislu.

6.4.2. Grangerova uzročnost između odabranih varijabli

Varijabla utječe na drugu varijablu ako neka prošla realizacija utječe na sadašnju realizaciju. Uzročnost u Grangerovom smislu lako se testira u VAR okruženju.

Iz VAR modela (Prilogu 7.) promatraju se vrijednosti dobivene F-testom koji se koristi za testiranje više parametara odjednom.

Varijabla broj zaposlenih:

Iz p-vrijednosti F-testa može se zaključiti da se hipoteza ne može odbaciti u sva tri slučaja, odnosno, vidljivo je kako sve tri promatrane varijable (nominalne i realne bruto plaće te inflacija) ne utječu na broj zaposlenih.

Varijabla nominalne bruto plaće:

Iz p-vrijednosti F-testa može se zaključiti da broj zaposlenih, realne bruto plaće i temeljna inflacija utječu na nominalne bruto plaće jer je p-vrijednost manja od 0,05 u sva tri slučaja.

Varijabla realne bruto plaće:

Iz p-vrijednosti F-testa može se zaključiti da broj zaposlenih, nominalne bruto plaće i temeljna inflacija utječu na realne bruto plaće u Grangerovom smislu jer su p-vrijednosti manje od 0,05.

Varijabla temeljna inflacija:

Iz p-vrijednosti F-testa može se zaključiti da nominalne i realne bruto plaće utječu na temeljnu inflaciju jer su p-vrijednosti manje od 0,05 dok broj zaposlenih ne utječe na temeljnu inflaciju jer je p-vrijednost veća od 0,05 (p-vrijednost = 0,1727).

6.4.3. Doprinos varijabli na prognostičku grešku kroz 30 kvartala

U daljnjoj analizi će se prikazati koliko jedna varijabla objašnjava drugu varijablu po kvartalima, odnosno koja varijabla objašnjava više drugu varijablu kroz 30 kvartala.

Tablica 8. *Dekompozicija varijance prognostičke greške za varijablu broj zaposlenih*

Decomposition of variance for l_brojzaposlenih					
period	std. error	l_brojzaposlenih	l_nominalnebrutoplace	l_realnebrutoplace	l_temeljnainflacija
1	0,00408488	100,0000	0,0000	0,0000	0,0000
2	0,0075728	98,6944	0,0500	0,0986	1,1570
3	0,010804	95,6336	0,0249	0,4782	3,8633
4	0,0137451	91,0376	0,0718	1,2542	7,6364
5	0,0164239	85,4327	0,2704	2,4642	11,8327
6	0,0188743	79,4189	0,6325	4,0545	15,8940
7	0,0211205	73,4980	1,1227	5,9070	19,4723
8	0,0231771	68,0080	1,6848	7,8828	22,4243
9	0,0250528	63,1290	2,2634	9,8586	24,7490
10	0,0267544	58,9197	2,8155	11,7441	26,5207
11	0,0282899	55,3603	3,3138	13,4851	27,8408
12	0,0296693	52,3888	3,7451	15,0563	28,8097
13	0,0309047	49,9263	4,1064	16,4534	29,5139
14	0,0320098	47,8916	4,4011	17,6846	30,0228
15	0,0329984	46,2097	4,6363	18,7650	30,3890
16	0,033884	44,8153	4,8203	19,7125	30,6519
17	0,0346791	43,6530	4,9619	20,5455	30,8397
18	0,0353946	42,6774	5,0687	21,2809	30,9729
19	0,0360401	41,8519	5,1479	21,9343	31,0660
20	0,0366234	41,1470	5,2052	22,5186	31,1292
21	0,0371515	40,5395	5,2453	23,0452	31,1700
22	0,0376298	40,0114	5,2720	23,5230	31,1936
23	0,038063	39,5483	5,2884	23,9595	31,2038
24	0,0384553	39,1395	5,2967	24,3605	31,2033
25	0,03881	38,7763	5,2989	24,7306	31,1941
26	0,0391302	38,4522	5,2963	25,0735	31,1780
27	0,0394186	38,1619	5,2901	25,3920	31,1560
28	0,0396777	37,9014	5,2810	25,6882	31,1294
29	0,0399099	37,6673	5,2698	25,9639	31,0990
30	0,0401171	37,4569	5,2571	26,2205	31,0655

Izvor: izrada autora u Gretl-u

Varijabla broj zaposlenih u prvom kvartalu objašnjava samu sebe sa 100%. U posljednjem promatranom horizontu varijabla samu sebe objašnjava sa 37,46%, dok ju varijabla nominalne bruto plaće objašnjava sa 5,26%, realne bruto plaće sa 26,22%, a temeljna inflacija sa 31,07%

Nadalje, vidljivo je da varijabla temeljna inflacija značajnije počinje utjecati na varijablu broj zaposlenih nakon 5-og kvartala. Također, varijabla realne bruto plaće značajnije počinju utjecati nakon 10-og kvartala. Sve tri promatrane varijable svakim kvartalom utječu sve više na varijablu broj zaposlenih, počevši od drugog kvartala.

Tablica 9. *Dekompozicija varijance prognostičke greške za varijablu nominalne bruto plaće*

Decomposition of variance for l_nominalnebrutoplace					
period	std. error	l_brojzaposlenih	l_nominalnebrutoplace	l_realnebrutoplace	l_temeljnainflacija
1	0,0073773	6,1495	93,8505	0,0000	0,0000
2	0,0102557	8,4404	82,0782	1,2595	8,2218
3	0,0129594	11,7726	67,2103	2,4913	18,5258
4	0,0156208	15,4986	55,8186	2,7862	25,8966
5	0,0182148	19,0137	47,9324	2,4830	30,5709
6	0,0207519	21,9775	42,3844	2,0098	33,6283
7	0,0232517	24,2928	38,3081	1,6015	35,7976
8	0,0257266	26,0058	35,1882	1,3498	37,4562
9	0,0281801	27,2211	32,7239	1,2742	38,7808
10	0,0306101	28,0512	30,7314	1,3628	39,8546
11	0,0330115	28,5956	29,0898	1,5916	40,7230
12	0,0353787	28,9339	27,7147	1,9336	41,4178
13	0,0377063	29,1270	26,5447	2,3626	41,9657
14	0,0399899	29,2194	25,5346	2,8555	42,3905
15	0,0422257	29,2435	24,6507	3,3929	42,7130
16	0,0444108	29,2217	23,8676	3,9594	42,9513
17	0,0465429	29,1699	23,1664	4,5427	43,1210
18	0,0486202	29,0986	22,5327	5,1339	43,2347
19	0,0506413	29,0149	21,9558	5,7261	43,3032
20	0,0526051	28,9232	21,4273	6,3144	43,3351
21	0,0545106	28,8268	20,9406	6,8950	43,3375
22	0,0563572	28,7274	20,4906	7,4656	43,3163
23	0,0581442	28,6263	20,0732	8,0243	43,2762
24	0,0598711	28,5243	19,6848	8,5700	43,2209
25	0,0615377	28,4220	19,3228	9,1016	43,1535
26	0,0631438	28,3199	18,9846	9,6188	43,0767
27	0,0646892	28,2182	18,6683	10,1212	42,9923
28	0,0661742	28,1173	18,3719	10,6086	42,9022
29	0,0675989	28,0174	18,0939	11,0810	42,8078
30	0,0689636	27,9187	17,8329	11,5383	42,7102

Izvor: izrada autora u Gretl-u

Varijabla nominalne bruto plaće u prvom kvartalu objašnjava samu sebe sa 93,85% dok ju broj zaposlenih objašnjava sa 6,15%. U posljednjem horizontu promatrana varijabla samu sebe objašnjava sa 17,83% dok ju varijabla broj zaposlenih objašnjava sa 27,92%, realne bruto plaće sa 11,54% a temeljna inflacija sa 42,71%. Nadalje, varijabla broj zaposlenih značajnije počinje utjecati na promatranu varijablu nakon otprilike 5-og kvartala te utjecaj se povećava sve do 20-og kvartala nakon čega kreće stabiliziranje utjecaja. Varijabla temeljna inflacija počinje značajnije utjecati nakon trećeg kvartala te nakon 26-og kvartala utjecaj kreće prema stabiliziranju. Varijabla realne bruto plaće ima blage oscilacije utjecaja na varijablu broj zaposlenih tijekom 30 kvartala te najveći utjecaj ima u 30-om kvartalu.

Tablica 10. *Dekompozicija varijance prognostičke greške za varijablu realne bruto plaće*

Decomposition of variance for l_realnebrutoplace					
period	std. error	l_brojzaposlenih	l_nominalnebrutoplace	l_realnebrutoplace	l_temeljnainflacija
1	0,0085128	3,1245	61,9878	34,8877	0,0000
2	0,0119262	5,0486	52,6155	34,1662	8,1697
3	0,0147652	8,3357	42,9323	29,9724	18,7597
4	0,0173827	12,1642	35,5142	26,2818	26,0399
5	0,019813	15,7683	30,3363	23,7940	30,1014
6	0,0220773	18,7489	26,7116	22,2431	32,2963
7	0,0241987	21,0157	24,0937	21,3075	33,5831
8	0,026194	22,6410	22,1391	20,7693	34,4506
9	0,0280743	23,7523	20,6395	20,4983	35,1099
10	0,0298458	24,4773	19,4652	20,4154	35,6421
11	0,0315127	24,9242	18,5302	20,4687	36,0770
12	0,0330781	25,1774	17,7743	20,6200	36,4283
13	0,0345455	25,2996	17,1539	20,8403	36,7062
14	0,0359187	25,3363	16,6366	21,1066	36,9205
15	0,0372021	25,3193	16,1980	21,4015	37,0811
16	0,0384003	25,2703	15,8203	21,7123	37,1971
17	0,0395181	25,2036	15,4901	22,0298	37,2765
18	0,0405604	25,1284	15,1976	22,3475	37,3264
19	0,0415319	25,0503	14,9355	22,6615	37,3527
20	0,0424371	24,9724	14,6984	22,9692	37,3600
21	0,0432801	24,8965	14,4822	23,2689	37,3524
22	0,0440649	24,8230	14,2840	23,5599	37,3330
23	0,0447951	24,7523	14,1014	23,8420	37,3043
24	0,0454738	24,6841	13,9327	24,1149	37,2683
25	0,0461042	24,6183	13,7763	24,3789	37,2265
26	0,0466891	24,5545	13,6311	24,6340	37,1804
27	0,0472311	24,4926	13,4961	24,8804	37,1309
28	0,0477326	24,4325	13,3705	25,1182	37,0788
29	0,0481959	24,3740	13,2536	25,3475	37,0249
30	0,0486232	24,3170	13,1447	25,5684	36,9698

Izvor: izrada autora u Gretl-u

Promatrana varijabla realne bruto plaće u prvom horizontu objašnjava sama sebe sa 34,89% dok ju broj zaposlenih objašnjava sa 3,12%, a nominalne bruto plaće sa 61,99%. U zadnjem horizontu promatrana varijabla objašnjava samu sebe sa 25,57% dok ju broj zaposlenih objašnjava sa 24,32%, nominalne bruto plaće sa 13,14% a temeljna inflacija sa 36,97%. Nadalje, varijabla broj zaposlenih značajnije počinje utjecati na promatranu varijablu u petom kvartalu gdje ju objašnjava sa 12,16% te nakon 20-og kvartala se počinje stabilizirati utjecaj. Varijabla nominalne bruto plaće u prvom kvartalu ima najveći utjecaj te s odmicanjem kvartala utjecaj se smanjuje. Temeljna inflacija značajnije počinje utjecati u trećem kvartalu sa 18,76% te se u 30-om kvartalu utjecaj se počinje smanjivati, tj. kreće se prema stabilizaciji utjecaja.

Tablica 11. Dekompozicija varijance prognostičke greške za varijablu temeljna inflacija

Decomposition of variance for l_temeljna inflacija					
period	std. error	l_brojzaposlenih	l_nominalnebrutoplace	l_realnebrutoplace	l_temeljna inflacija
1	0,00484176	1,6552	3,6770	34,9768	59,6909
2	0,00762381	1,5132	2,2148	44,2633	52,0087
3	0,00954969	1,7863	1,6280	53,4881	43,0976
4	0,0109425	2,3708	1,3687	60,8925	35,3680
5	0,0119958	3,2062	1,3173	65,7534	29,7232
6	0,0128194	4,2121	1,4801	68,2578	26,0500
7	0,0134888	5,3077	1,8938	68,8872	23,9113
8	0,0140631	6,4322	2,5713	68,1038	22,8927
9	0,014587	7,5493	3,4864	66,2858	22,6786
10	0,015092	8,6436	4,5819	63,7398	23,0348
11	0,0155987	9,7128	5,7864	60,7175	23,7832
12	0,0161196	10,7609	7,0296	57,4231	24,7864
13	0,0166618	11,7922	8,2513	54,0177	25,9388
14	0,0172289	12,8088	9,4059	50,6236	27,1617
15	0,0178226	13,8089	10,4629	47,3304	28,3978
16	0,0184428	14,7871	11,4049	44,2006	29,6074
17	0,0190886	15,7354	12,2251	41,2759	30,7636
18	0,0197582	16,6448	12,9245	38,5812	31,8494
19	0,0204492	17,5067	13,5093	36,1291	32,8550
20	0,021159	18,3135	13,9889	33,9221	33,7755
21	0,0218843	19,0600	14,3744	31,9555	34,6101
22	0,0226219	19,7430	14,6773	30,2194	35,3603
23	0,0233683	20,3616	14,9088	28,7001	36,0295
24	0,0241203	20,9168	15,0793	27,3815	36,6224
25	0,0248746	21,4110	15,1984	26,2466	37,1441
26	0,025628	21,8477	15,2743	25,2778	37,6003
27	0,0263777	22,2313	15,3143	24,4579	37,9966
28	0,027121	22,5662	15,3246	23,7705	38,3387
29	0,0278554	22,8571	15,3106	23,2002	38,6320
30	0,0285787	23,1087	15,2768	22,7330	38,8816

Izvor: izrada autora u Gretl-u

Promatrajući dekompoziciju varijance prognostičke greške za varijablu temeljna inflacija, ista objašnjava samu sebe sa 59,69% dok ju broj zaposlenih objašnjava sa 1,65%, nominalne bruto plaće sa 3,67% a realne bruto plaće sa 34,98%. U posljednjem horizontu temeljna inflacija objašnjava samu sebe sa 38,88% dok ju broj zaposlenih objašnjava sa 23,11%, nominalne bruto plaće sa 15,28% i realne bruto plaće sa 22,73%. Nadalje, utjecaj varijable broj zaposlenih se povećava kroz svih 30 kvartala. Isto tako, utjecaj nominalnih bruto plaća se tijekom kvartala povećava, ali se u 29-om kvartalu utjecaj počinje smanjivati. Varijabla realne bruto plaće u prvim kvartalima ima najveći utjecaj te se nakon sedmog kvartala, u kojemu objašnjava promatranu varijablu sa 68,89%, utjecaj počinje stabilizirati.

7. ZAKLJUČAK I KRITIČKI OSVRT

Broj zaposlenih u Hrvatskoj, statistički, u posljednjih nekoliko godina raste. Zavodi koji prikupljaju podatke o kretanjima na tržištu rada imaju različitu terminologiju, definiciju zaposlenosti te svoju metodologiju prikupljanja podataka. Objavljivanje podataka o zaposlenosti različitih zavoda može dovesti do konfuzije i subjektivnog tumačenja. Od tri Zavoda koja prate kretanja na tržištu rada može se reći da je relevantan Državni zavod za statistiku. Hrvatski zavod za zapošljavanje (HZZ) ukazuje na one koje aktivno traže posao i na mjere aktivne politike zapošljavanja. HZZ u određenim analizama ne treba uzimati u obzir, kao niti Hrvatski zavod za mirovinsko osiguranje (HZMO) koji prikuplja podatke o osiguranicima, ukoliko se želi doći do relativno stvarnih podataka o broju zaposlenih. HZMO je najomiljeniji političarima jer osiguranike tumači kao zaposlene osobe, što ni u kojem slučaju nije isto. Broj osiguranika u apsolutnom broju je uvijek veći od broja zaposlenih, što znači da osiguranici tako mogu biti i nezaposlene osobe koje ispunjavaju prava iz Zakona o mirovinskog osiguranju.

Rast zaposlenih, s jedne strane je vrlo važan parametar, u nekim sferama čak i važniji od nezaposlenosti. To znači da analize o nezaposlenosti treba uzimati i koristiti s rezervom jer je, analizirajući trenutno stanje u Hrvatskoj, pad upravo tog pokazatelja najvećim dijelom uzrokovan odlaskom radno aktivnog stanovništva u inozemstvo. Vrlo je jasno da u Hrvatskoj često se ne vode ekonomske politike koje bi poticale otvaranje novih radnih mjesta (kao što to političari vole isticati). Treba istaknuti da pad nezaposlenosti ne dovodi do stvarnog povećanja zaposlenosti.

Nadalje, istina je da se Hrvatska počela oporavljati od gospodarske krize, sporo ali (relativno) sigurno. Otkako je Hrvatska počela izlaziti iz gospodarske recesije, plaće su tijekom nekoliko godina realno porasle oko 5%, prema podacima DZS-a. Promatrajući statistiku bruto ili neto plaća u Hrvatskoj, prosječne plaće ne izgledaju (toliko) loše. Međutim, problem je u tome što velika većina zaposlenih u Hrvatskoj prima ispodprosječne plaće, a može se reći čak i minimalne. Protekla godina se može istaknuti kao godina u kojoj se dosta pričalo kako u Hrvatskoj plaće rastu. No,

potrebno je naglasiti da su najveće povišice dobili oni zaposleni s najvišim plaćama (koji zapravo i podižu statistiku plaća i ne daju realnu sliku stanja u Hrvatskoj), a zaposleni s najnižim plaćama (kojih je najviše) dobili su najmanje povišice.

Sljedeći problem koji se javlja su mirovine. Generacija rođena između pedesetih i šezdesetih godina prošloga stoljeća koja je relativno ugodno proživjela svoj radni vijek i „punila“ blagajnu za isplatu mirovina svojih roditelja, našla se u velikom, skoro pa i neizlaznom problemu. Danas za njihove mirovine od njihove štednje ostaje tek ono što su uplatili u drugi stup (ako su bili dovoljno mladi da se 2002. godine priključe toj vrsti štednje). Broj onih koji su se odlučili za uplate dodatne mirovinske štednje u trećem stupu je, s lakoćom se može reći, potpuno zanemariv. Uz odljev stanovništva, uz negativan prirast i uz sve veći broj umirovljenog stanovništva, mirovinski sustav je pred raspadom. Omjer 1,16 zaposlenih na jednog umirovljenika dugoročno je neodrživ.

Posljednjih godina svjedoci smo povećanju cijena hrane i pića (alkoholnih i bezalkoholnih), usluga restorana i hotela, duhana, cestarina itd. što ukazuje na pozitivnu stopu inflacije od kraja 2016. godine do danas. Većina ekonomista se slaže da je rast cijena poželjan ako je umjeren. Inflacija je redovita popratna pojava svakog gospodarskog napretka. Smatra se da je prihvatljiva stopa inflacije koja ne prelazi 10% godišnje. Međutim, deflacija, koja je u Hrvatskoj od 2014. godine dovela do padanja cijena u rasponu od 0,2% do 1,1% godišnje, najčešće je negativna pojava. Deflacija je zapravo znak gospodarske stagnacije, rasta dugova i kolektivnog propadanja. S druge strane, inflacija izazvana povećavanjem poreza možda i nije najpametnija odluka. Dolazi do poticanja rasta (ionako) prevelike sive ekonomije malih i srednjih poduzeća te općenito „gušenja“ poduzetništva, a u Hrvatskoj su pokretači gospodarstva upravo mala i srednja poduzeća kojih ima najveći broj. Gledajući širu sliku, analitičari iz Hrvatske gospodarske komore, povezuju povratak inflacije u Hrvatsku sa poskupljenjem nafte i sirovina na svjetskom tržištu. Također, Ekonomski institut iz Zagreba procjenjuje rast potrošačkih cijena. Hoće li plaće i mirovine sustizati taj rast ostat će otvoreno pitanje. Jedno je sigurno, da bi se građanima Hrvatske poboljšao životni standard, njihovi dohoci moraju rasti brže od potrošačkih cijena.

Naposljetku, u metodološkom dijelu ovoga rada i kroz prikaz utjecaja odabranih varijabli kroz 30 kvartala, može se zaključiti sljedeće: nominalne i realne plaće te temeljna inflacija ne utječu na broj zaposlenih u Hrvatskoj. Prema Grangerovoj uzročnosti realne bruto plaće, broj zaposlenih i inflacija utječu na nominalne bruto plaće dok proučavajući utjecaj kroz 30 kvartala ukazuje se da samo zaposleni utječu na nominalne bruto plaće. Na realne bruto plaće najveći utjecaj ima broj zaposlenih te nominalne bruto plaće, a prema Grangeru utjecaj ima i temeljna inflacija. Što se tiče temeljne inflacije, koja se prema HNB-u utvrđuje na način da se iz indeksa cijena na malo isključe one komponente čije kretanje je u značajnoj mjeri izvan kontrole monetarne vlasti (cijene poljoprivrednih proizvoda i administrativno regulirane cijene), metodološki pristup u ovome radu ukazuje da niti jedna promatrana varijabla značajno ne utječe na inflaciju - *značajno* zbog toga što u Grangerovom smislu plaće ipak utječu na temeljnu inflaciju.

LITERATURA

KNJIGE:

1. Babić M. (1995.), *Makroekonomija*, Zagreb: Mate d.o.o.
2. Benić Đ., (2016.), *Makroekonomija*, Školska knjiga, Zagreb
3. Bogunović A., Sharma S., (1995.), *Narodno gospodarstvo: osnove teorije i prakse*, Art Studio Azinović, Zagreb
4. Bušelić M. (2014.), *Tržište rada: teorijski pristup*, Sveučilište Jurja Dobrile, Fakultet za ekonomiju i turizam „Dr. Mijo Mirković“, Pula
5. Grgić M., Bilas V. (2008.) *Međunarodna ekonomija*. Zagreb: Lares plus d.o.o.
6. Sharma S., Tomić D. (2012.), *Ekonomska politika i makroekonomski management*, Mikrorad, Zagreb

ZNANSVENI ČLANCI, PUBLIKACIJE, ČASOPISI:

1. Bejaković P., Nezaposlenost i zaposlenost, dostupno na:
<http://www.ijf.hr/rosen/rosenic/zaposlenost.pdf>
2. Benić Đ. (2014.), *Povijest razvoja teorije o odnosu između inflacije i nezaposlenosti*, Ekonomska misao i praksa DBK. god XXIII., Br.2., dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=193320
3. Bejaković P. (2015.) Problemi, mogućnosti i ograničenja postojanja minimalne plaće u Hrvatskoj, Profil javne politike, br.24, dostupno na:
<https://hrcak.srce.hr/156899>
4. Benić Đ. (2014.) *Monetarna politika: transparentnost središnje banke i ciljana inflacija*, Ekonomska misao i praksa DBK. God XXIII. Br. 1., dostupno na:
https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=182466
5. Jakšić S., Škrinjarić T. (2010.) *Analiza učinaka odabranih makroekonomskih varijabli na inflaciju u Hrvatskoj za razdoblje 2000. - 2009. godine*, Zbornik Ekonomskog fakulteta u Zagrebu, godina 8, br.2, dostupno na:
https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=105345
6. Kerovec N. (1999.), *Kako mjeriti nezaposlenost*, Pregledni članak, Hrvatski zavod za zapošljavanje, Zagreb, dostupno na: <https://hrcak.srce.hr/file/47273>

7. Kunovac M., Pufnik A. (2015.) *Obilježja tržišta rada i određivanja plaća u Hrvatskoj: rezultati Anketa poduzeća*, Hrvatska narodna banka, dostupno na: <http://www.hnb.hr/documents/20182/265578/p-027/28c3339e-b94a-4fc6-8c0a-626f1738a6cb>
8. Nadoveza O., Šimurina J. (2010.), *Prognoziranje inflacije - primjer Hrvatske*, Zbornik Ekonomskog fakulteta u Zagrebu, godina 8, br.2., dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=105344
9. Nestić D., Rubil I., Tomić I. (2015.) *Analiza razlika u plaćama između javnog sektora, poduzeća u državnom vlasništvu i privatnog sektora u Hrvatskoj 2000.-2012.*, Privredna kretanja i ekonomska politika, Zagreb, god.24, br.1 (136), dostupno na: <https://hrcak.srce.hr/140042>
10. Okun (1962.) *Potential GNP: Its Measurement and Significance*, Cowless Foundation, Yale University, dostupno na: <https://mileskorak.files.wordpress.com/2016/01/okun-potential-gnp-its-measurement-and-significance-p0190.pdf>
11. Tomić D. (2009.) *Testiranje Okunova zakona u hrvatskom gospodarstvu*, Magistarski rad, Sveučilište Jurja Dobrile u Puli, Odjel za ekonomiju i turizam „dr.Mijo Mirković“, Pula
12. Vidović D. (2015.) *Zaposlimo Hrvatsku, Strateške smjernice za rast zaposlenosti*, Hrvatska gospodarska komora, Zagreb, dostupno na: http://predsjednica.hr/files/zaposlimo_hrvatsku_publikacija.pdf

INTERNET IZVORI:

1. Birač D. (2014), *Što se događa s realnim plaćama u Hrvatskoj?*, dostupno na: <http://www.index.hr/vijesti/clanak/sto-se-dogadja-s-realnim-placama-u-hrvatskoj/742804.aspx>
2. Crnički N. (2014.), *Bruto plaća*, dostupno na: <https://isplate.info/bruto-placa.aspx>
3. Encyclopedia Britannica, dostupno na: <https://www.britannica.com/biography/Arthur-M-Okun>
4. Kelebuš I. (2013.) *Zaposlenost i nezaposlenost u Hrvatskoj i EU*, dostupno na: <https://www.teb.hr/novosti/2013/zaposlenost-i-nezaposlenost-u-hrvatskoj-i-eu/>

5. Lider (2018.), *Eurostat: Stopa nezaposlenosti u EU stagnira, u Hrvatskoj opada*, dostupno na: <https://lider.media/aktualno/biznis-i-politika/hrvatska/eurostat-stopa-nezaposlenosti-u-eu-stagnira-u-hrvatskoj-opada/>
6. Lider (2018.), *Unatoč najvećem rastu, zaposlenost u Hrvatskoj najniža u EU*, dostupno na: <https://lider.media/aktualno/biznis-i-politika/hrvatska/unatoc-najvecem-rastu-zaposlenost-u-hrvatskoj-najniza-u-eu/>
7. Podgornik B., (2017.), *Nakon tri godine u Hrvatsku se vratila inflacija: Evo što to zapravo znači*, dostupno na: http://www.novilist.hr/Vijesti/Hrvatska/Nakon-tri-godine-u-Hrvatsku-se-vratila-inflacija-Evo-sto-to-zapravo-znaci?meta_refresh=true
8. Poslovni.hr/Hina (2017.), *Prosječna bruto plaća u Hrvatskoj iznosi 7.945 kuna*, dostupno na: <http://www.poslovni.hr/hrvatska/prosjecna-bruto-placa-u-hrvatskoj-iznosi-7945-kuna-329549>
9. *Stiglo novo izvješće o minimalnim plaćama: Evo u kojim zemljama je minimalac najveći i kako stoji Hrvatska*, (2017.), dostupno na: <https://net.hr/danas/hrvatska/stiglo-novo-izvjesce-o-minimalnim-placama-evo-u-kojim-zemljama-je-minimalac-najveci-i-kako-stoji-hrvatska/>

POPIS GRAFIKONA

Grafikon 1. Kretanje inflacije u Hrvatskoj od 2011. godine do 2018. godine

Grafikon 2. Indeksi potrošačkih cijena

Grafikon 3. Kretanje varijabli: broj zaposlenih, nominalne bruto plaće, realne bruto plaće, temeljna inflacija (indeks) od 1999. godine do 2016. godine u Hrvatskoj

Grafikon 4. Kretanje varijabli dodavanjem prve diferencije od 1999. godine do 2016. godine u Hrvatskoj

POPIS TABLICA

<u>Tablica 1.</u>	Zaposleni i nezaposleni od 1999. do 2016. godine
<u>Tablica 2.</u>	Doseljeno stanovništvo iz inozemstva u RH od 2011. do 2016. godine
<u>Tablica 3.</u>	Odseljeno stanovništvo iz inozemstva u RH od 2011. do 2016. godine
<u>Tablica 4.</u>	Prosječne mjesečne bruto plaće u Hrvatskoj u kunama
<u>Tablica 5.</u>	Prosječne mjesečne neto plaće u Hrvatskoj u kunama
<u>Tablica 6.</u>	Inflacija u Hrvatskoj od 2011. godine do 2017. godine po mjesecima
<u>Tablica 7.</u>	Indeksi potrošačkih cijena
<u>Tablica 8.</u>	Dekompozicija varijance prognostičke greške za varijablu Broj zaposlenih
<u>Tablica 9.</u>	Dekompozicija varijance prognostičke greške za varijablu Nominalne bruto plaće
<u>Tablica 10.</u>	Dekompozicija varijance prognostičke greške za varijablu Realne bruto plaće
<u>Tablica 11.</u>	Dekompozicija varijance prognostičke greške za varijablu Temeljna inflacija

POPIS SLIKA

- Slika 1. Dickey-fuller test za varijablu broj zaposlenih
- Slika 2. Dickey-fuller test za varijablu nominalne bruto plaće
- Slika 3. Stacioniranje varijable nominalne bruto plaće pomoću Dickey-fuller testa
- Slika 4. Dickey-fuller test za varijablu realne bruto plaće
- Slika 5. Stacioniranje varijable realne bruto plaće pomoću Dickey-fuller testa
- Slika 6. Dickey-fuller test za varijablu temeljna inflacija
- Slika 7. Broj vremenskih pomaka
- Slika 8. Test autokorelacije u VAR modelu
- Slika 9. Utjecaj varijabli na broj zaposlenih kroz 30 godina
- Slika 10. Utjecaj varijabli na nominalne bruto plaće kroz 30 godina
- Slika 11. Utjecaj varijabli na realne bruto plaće kroz 30 godina
- Slika 12. Utjecaj varijabli na temeljnu inflaciju kroz 30 godina

PRILOG

PRILOG 1. Dickey-fuller test za varijablu broj zaposlenih

```
Augmented Dickey-Fuller test for brojzaposlenih
including one lag of (1-L)brojzaposlenih
(max was 4, criterion t-statistic)
sample size 66
unit-root null hypothesis: a = 1

test with constant
model: (1-L)y = b0 + (a-1)*y(-1) + ... + e
estimated value of (a - 1): -0,0224816
test statistic: tau_c(1) = -1,73968
asymptotic p-value 0,4112
1st-order autocorrelation coeff. for e: -0,132

Augmented Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 (T = 66)
Dependent variable: d_brojzaposlenih
```

	coefficient	std. error	t-ratio	p-value	
const	33,5398	19,1393	1,752	0,0846	*
brojzaposlenih_1	-0,0224816	0,0129228	-1,740	0,4112	
d_brojzaposlen~_1	0,716119	0,0845909	8,466	5,49e-012	***

AIC: 439,773 BIC: 446,342 HQC: 442,369

```
with constant and trend
model: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
estimated value of (a - 1): -0,0199939
test statistic: tau_ct(1) = -1,46694
asymptotic p-value 0,8409
1st-order autocorrelation coeff. for e: -0,129

Augmented Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 (T = 66)
Dependent variable: d_brojzaposlenih
```

	coefficient	std. error	t-ratio	p-value	
const	30,8439	19,7508	1,562	0,1235	
brojzaposlenih_1	-0,0199939	0,0136297	-1,467	0,8409	
d_brojzaposlen~_1	0,703236	0,0876720	8,021	3,64e-011	***
time	-0,0277985	0,0461580	-0,6022	0,5492	

AIC: 441,388 BIC: 450,147 HQC: 444,849

PRILOG 2. Dickey-fuller test za varijablu nominalne bruto plaće

Augmented Dickey-Fuller test for nominalnebrutoplace
including one lag of (1-L)nominalnebrutoplace
(max was 4, criterion t-statistic)
sample size 66
unit-root null hypothesis: $a = 1$

test with constant
model: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$
estimated value of $(a - 1)$: -0,016927
test statistic: $\tau_c(1) = -2,40963$
asymptotic p-value 0,139
1st-order autocorrelation coeff. for e: -0,017

Augmented Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 ($T = 66$)
Dependent variable: d_nominalnebrutoplace

	coefficient	std. error	t-ratio	p-value	
const	144,893	49,9215	2,902	0,0051	***
nominalnebruto~_1	-0,0169270	0,00702470	-2,410	0,1390	
d_nominalnebru~_1	0,333871	0,115717	2,885	0,0053	***

AIC: 734,815 BIC: 741,384 HQC: 737,41

with constant and trend
model: $(1-L)y = b_0 + b_1*t + (a-1)y(-1) + e$
estimated value of $(a - 1)$: 0,0355206
test statistic: $\tau_{ct}(1) = 1,60187$
p-value 1
1st-order autocorrelation coeff. for e: 0,200

Dickey-Fuller regression
OLS, using observations 1999:2-2015:4 ($T = 67$)
Dependent variable: d_nominalnebrutoplace

	coefficient	std. error	t-ratio	p-value	
const	-50,4320	102,546	-0,4918	0,6245	
nominalnebruto~_1	0,0355206	0,0221745	1,602	1,0000	
time	-3,89076	1,36991	-2,840	0,0060	***

AIC: 745,263 BIC: 751,877 HQC: 747,88

PRILOG 3. Stacioniranje varijable realne bruto plaće pomoću Dicky-fuller testa

```

Augmented Dickey-Fuller test for d_realnebrutoplace
including 0 lags of (1-L)d_realnebrutoplace
(max was 4, criterion t-statistic)
sample size 66
unit-root null hypothesis: a = 1

test with constant
model: (1-L)y = b0 + (a-1)*y(-1) + e
estimated value of (a - 1): -0,77215
test statistic: tau_c(1) = -6,40118
p-value 5,625e-007
1st-order autocorrelation coeff. for e: 0,014

Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 (T = 66)
Dependent variable: d_d_realnebrutoplace

      coefficient  std. error  t-ratio  p-value
-----
const          11,1163      9,44487    1,177    0,2436
d_realnebrutop~1 -0,772150    0,120626  -6,401  5,62e-07 ***
AIC: 759,669   BIC: 764,048   HQC: 761,4

```

PRILOG 4. Dickey-fuller test za varijablu realne bruto plaće

```

Augmented Dickey-Fuller test for realnebrutoplace
including 0 lags of (1-L)realnebrutoplace
(max was 4, criterion t-statistic)
sample size 67
unit-root null hypothesis: a = 1

test with constant
model: (1-L)y = b0 + (a-1)*y(-1) + e
estimated value of (a - 1): -0,0492829
test statistic: tau_c(1) = -2,73047
p-value 0,07425
1st-order autocorrelation coeff. for e: 0,192

Dickey-Fuller regression
OLS, using observations 1999:2-2015:4 (T = 67)
Dependent variable: d_realnebrutoplace

      coefficient  std. error  t-ratio  p-value
-----
const      370,589    130,128    2,848    0,0059 ***
realnebrutopla~_1 -0,0492829    0,0180492 -2,730    0,0742 *

AIC: 768,333   BIC: 772,742   HQC: 770,078

with constant and trend
model: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
estimated value of (a - 1): -0,00316594
test statistic: tau_ct(1) = -0,112123
asymptotic p-value 0,9947
1st-order autocorrelation coeff. for e: 0,004
lagged differences: F(2, 60) = 1,699 [0,1915]

Augmented Dickey-Fuller regression
OLS, using observations 1999:4-2015:4 (T = 65)
Dependent variable: d_realnebrutoplace

      coefficient  std. error  t-ratio  p-value
-----
const      98,2856    182,985    0,5371    0,5932
realnebrutopla~_1 -0,00316594    0,0282362 -0,1121    0,9947
d_realnebrutop~_1  0,110127    0,131455    0,8378    0,4055
d_realnebrutop~_2 -0,219175    0,132800   -1,650    0,1041
time      -1,65372    0,825005   -2,004    0,0495 **

AIC: 745,482   BIC: 756,354   HQC: 749,772

```

PRILOG 5. Stacioniranje varijable nominalne bruto plaće pomoću Dicky-fuller testa

```
Augmented Dickey-Fuller test for d_nominalnebrutoplace
including 0 lags of (1-L)d_nominalnebrutoplace
(max was 4, criterion t-statistic)
sample size 66
unit-root null hypothesis: a = 1

test with constant
model: (1-L)y = b0 + (a-1)*y(-1) + e
estimated value of (a - 1): -0,561923
test statistic: tau_c(1) = -5,04916
p-value 7,754e-005
1st-order autocorrelation coeff. for e: -0,054

Dickey-Fuller regression
OLS, using observations 1999:3-2015:4 (T = 66)
Dependent variable: d_d_nominalnebrutoplace
```

	coefficient	std. error	t-ratio	p-value	
const	26,6968	9,62244	2,774	0,0072	***
d_nominalnebru~1	-0,561923	0,111290	-5,049	7,75e-05	***

AIC: 738,633 BIC: 743,013 HQC: 740,364

PRILOG 6. Dickey-fuller test za varijablu temeljna inflacija

```
Augmented Dickey-Fuller test for temeljnainflacija
including 2 lags of (1-L)temeljnainflacija
(max was 4, criterion t-statistic)
sample size 65
unit-root null hypothesis: a = 1

test with constant
model: (1-L)y = b0 + (a-1)*y(-1) + ... + e
estimated value of (a - 1): -0,011421
test statistic: tau_c(1) = -1,74141
asymptotic p-value 0,4103
1st-order autocorrelation coeff. for e: 0,027
lagged differences: F(2, 61) = 8,915 [0,0004]

Augmented Dickey-Fuller regression
OLS, using observations 1999:4-2015:4 (T = 65)
Dependent variable: d_temeljnainflacija
```

	coefficient	std. error	t-ratio	p-value	
const	1,19340	0,597454	1,997	0,0502	*
temeljnainflac~1	-0,0114210	0,00655849	-1,741	0,4103	
d_temeljnainfl~1	0,295002	0,122379	2,411	0,0190	**
d_temeljnainfl~2	0,263753	0,122121	2,160	0,0347	**

AIC: 88,9609 BIC: 97,6584 HQC: 92,3926

```
with constant and trend
model: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
estimated value of (a - 1): -0,0703677
test statistic: tau_ct(1) = -1,89496
asymptotic p-value 0,6571
1st-order autocorrelation coeff. for e: 0,009
lagged differences: F(2, 60) = 10,396 [0,0001]

Augmented Dickey-Fuller regression
OLS, using observations 1999:4-2015:4 (T = 65)
Dependent variable: d_temeljnainflacija
```

	coefficient	std. error	t-ratio	p-value	
const	5,31609	2,62449	2,026	0,0473	**
temeljnainflac~1	-0,0703677	0,0371341	-1,895	0,6571	
d_temeljnainfl~1	0,328282	0,122557	2,679	0,0095	***
d_temeljnainfl~2	0,328194	0,127006	2,584	0,0122	**
time	0,0292105	0,0181196	1,612	0,1122	

AIC: 88,2048 BIC: 99,0767 HQC: 92,4944

PRILOG 7. VAR model

VAR system, lag order 2
 OLS estimates, observations 1999:3-2015:4 (T = 66)
 Log-likelihood = 1032,6997
 Determinant of covariance matrix = 3,0152377e-019
 AIC = -30,2030
 BIC = -29,0087
 HQC = -29,7311
 Portmanteau test: LB(16) = 204,748, df = 224 [0,8173]

Equation 1: l_brojzaposlenih

	coefficient	std. error	t-ratio	p-value	
const	0,662102	0,368126	1,799	0,0774	*
l_brojzaposlen~_1	1,57378	0,103120	15,26	8,62e-022	***
l_brojzaposlen~_2	-0,609207	0,100070	-6,088	1,03e-07	***
l_nominalnebru~_1	0,0765317	0,149256	0,5128	0,6101	
l_nominalnebru~_2	0,0430410	0,164951	0,2609	0,7951	
l_realnebrutop~_1	-0,0767187	0,129604	-0,5919	0,5562	
l_realnebrutop~_2	0,000941340	0,136133	0,006915	0,9945	
l_temeljainfl~_1	-0,217755	0,130430	-1,670	0,1005	
l_temeljainfl~_2	0,0432466	0,140655	0,3075	0,7596	
Mean dependent var	7,298752	S.D. dependent var	0,042515		
Sum squared resid	0,001101	S.E. of regression	0,004396		
R-squared	0,990626	Adjusted R-squared	0,989311		
F(8, 57)	752,9762	P-value(F)	7,28e-55		
rho	-0,123668	Durbin-Watson	2,205003		

F-tests of zero restrictions:

All lags of l_brojzaposlenih	F(2, 57) =	373,18	[0,0000]
All lags of l_nominalnebruto~	F(2, 57) =	1,3049	[0,2792]
All lags of l_realnebrutopla~	F(2, 57) =	0,43844	[0,6472]
All lags of l_temeljainflac~	F(2, 57) =	2,4461	[0,0957]
All vars, lag 2	F(4, 57) =	10,234	[0,0000]

Equation 2: l_nominalnebrutoplace

	coefficient	std. error	t-ratio	p-value	
const	1,65582	0,664837	2,491	0,0157	**
l_brojzaposlen~_1	0,242871	0,186235	1,304	0,1974	
l_brojzaposlen~_2	0,0100791	0,180726	0,05577	0,9557	
l_nominalnebru~_1	1,56739	0,269558	5,815	2,89e-07	***
l_nominalnebru~_2	-0,156454	0,297903	-0,5252	0,6015	
l_realnebrutop~_1	-0,676598	0,234066	-2,891	0,0054	***
l_realnebrutop~_2	0,147524	0,245857	0,6000	0,5509	
l_temeljainfl~_1	-0,786125	0,235556	-3,337	0,0015	***
l_temeljainfl~_2	0,248177	0,254024	0,9770	0,3327	
Mean dependent var	8,798309	S.D. dependent var	0,181581		
Sum squared resid	0,003592	S.E. of regression	0,007938		
R-squared	0,998324	Adjusted R-squared	0,998089		
F(8, 57)	4243,948	P-value(F)	3,67e-76		
rho	-0,011729	Durbin-Watson	1,982666		

F-tests of zero restrictions:

All lags of l_brojzaposlenih	F(2, 57) =	7,1062	[0,0018]
All lags of l_nominalnebruto~	F(2, 57) =	65,930	[0,0000]
All lags of l_realnebrutopla~	F(2, 57) =	7,6606	[0,0011]
All lags of l_temeljainflac~	F(2, 57) =	8,3253	[0,0007]
All vars, lag 2	F(4, 57) =	0,31319	[0,8680]

Equation 3: l_realnebrutoplace

	coefficient	std. error	t-ratio	p-value	
const	2,05176	0,767167	2,674	0,0097	***
l_brojzaposlen~1	0,308795	0,214899	1,437	0,1562	
l_brojzaposlen~2	-0,0439735	0,208543	-0,2109	0,8337	
l_nominalnebru~1	0,469822	0,311047	1,510	0,1365	
l_nominalnebru~2	-0,0211992	0,343755	-0,06167	0,9510	
l_realnebrutop~1	0,441324	0,270093	1,634	0,1078	
l_realnebrutop~2	-0,0628316	0,283699	-0,2215	0,8255	
l_temeljainfl~1	-0,911275	0,271813	-3,353	0,0014	***
l_temeljainfl~2	0,373850	0,293123	1,275	0,2073	
Mean dependent var	8,882965	S.D. dependent var	0,066781		
Sum squared resid	0,004783	S.E. of regression	0,009160		
R-squared	0,983501	Adjusted R-squared	0,981185		
F(8, 57)	424,7068	P-value(F)	7,10e-48		
rho	-0,027270	Durbin-watson	1,982702		

F-tests of zero restrictions:

All lags of l_brojzaposlenih	F(2, 57) =	5,9639	[0,0044]
All lags of l_nominalnebruto~	F(2, 57) =	4,8740	[0,0111]
All lags of l_realnebrutopla~	F(2, 57) =	2,7458	[0,0727]
All lags of l_temeljaininflac~	F(2, 57) =	7,4456	[0,0013]
All vars, lag 2	F(4, 57) =	0,85617	[0,4958]

Equation 4: l_temeljaininflacija

	coefficient	std. error	t-ratio	p-value	
const	1,06797	0,436336	2,448	0,0175	**
l_brojzaposlen~1	0,0178436	0,122227	0,1460	0,8844	
l_brojzaposlen~2	0,0648205	0,118612	0,5465	0,5869	
l_nominalnebru~1	0,156889	0,176912	0,8868	0,3789	
l_nominalnebru~2	0,109665	0,195515	0,5609	0,5771	
l_realnebrutop~1	-0,219202	0,153619	-1,427	0,1591	
l_realnebrutop~2	-0,0558981	0,161357	-0,3464	0,7303	
l_temeljainfl~1	1,07715	0,154597	6,967	3,60e-09	***
l_temeljainfl~2	-0,427481	0,166717	-2,564	0,0130	**
Mean dependent var	4,479723	S.D. dependent var	0,104013		
Sum squared resid	0,001547	S.E. of regression	0,005210		
R-squared	0,997800	Adjusted R-squared	0,997491		
F(8, 57)	3231,243	P-value(F)	8,54e-73		
rho	-0,135653	Durbin-watson	2,250490		

F-tests of zero restrictions:

All lags of l_brojzaposlenih	F(2, 57) =	1,8112	[0,1727]
All lags of l_nominalnebruto~	F(2, 57) =	4,5535	[0,0146]
All lags of l_realnebrutopla~	F(2, 57) =	3,7295	[0,0300]
All lags of l_temeljaininflac~	F(2, 57) =	32,690	[0,0000]
All vars, lag 2	F(4, 57) =	2,4106	[0,0596]

For the system as a whole:

Null hypothesis: the longest lag is 1

Alternative hypothesis: the longest lag is 2

Likelihood ratio test: chi-square(16) = 56,7542 [0,0000]

Comparison of information criteria:

Lag order 2: AIC = -30,2030, BIC = -29,0087, HQC = -29,7311

Lag order 1: AIC = -29,8280, BIC = -29,1644, HQC = -29,5658

PRILOG 8. Testiranje heteroskedastičnosti u VAR modelu

Test for ARCH of order 4

Equation 1:

	coefficient	std. error	t-ratio	p-value	
alpha(0)	1,43861e-05	6,81493e-06	2,111	0,0392	**
alpha(1)	0,319929	0,131692	2,429	0,0183	**
alpha(2)	-0,171391	0,138052	-1,241	0,2195	
alpha(3)	0,0645669	0,137922	0,4681	0,6415	
alpha(4)	-0,0746961	0,131774	-0,5668	0,5730	

Null hypothesis: no ARCH effect is present

Test statistic: LM = 6,23162

with p-value = $P(\text{Chi-square}(4) > 6,23162) = 0,182506$

Equation 2:

	coefficient	std. error	t-ratio	p-value	
alpha(0)	4,02176e-05	1,99101e-05	2,020	0,0481	**
alpha(1)	-0,0749951	0,135763	-0,5524	0,5828	
alpha(2)	0,0831890	0,134727	0,6175	0,5394	
alpha(3)	0,153638	0,130947	1,173	0,2456	
alpha(4)	0,0419520	0,239373	0,1753	0,8615	

Null hypothesis: no ARCH effect is present

Test statistic: LM = 2,10226

with p-value = $P(\text{Chi-square}(4) > 2,10226) = 0,716958$

Equation 3:

	coefficient	std. error	t-ratio	p-value	
alpha(0)	8,37173e-05	2,50084e-05	3,348	0,0014	***
alpha(1)	-0,0618311	0,131992	-0,4684	0,6413	
alpha(2)	-0,103401	0,132054	-0,7830	0,4369	
alpha(3)	-0,00313771	0,132642	-0,02366	0,9812	
alpha(4)	-0,0565723	0,161048	-0,3513	0,7267	

Null hypothesis: no ARCH effect is present

Test statistic: LM = 0,961899

with p-value = $P(\text{Chi-square}(4) > 0,961899) = 0,915517$

Equation 4:

	coefficient	std. error	t-ratio	p-value	
alpha(0)	1,52475e-05	4,39625e-06	3,468	0,0010	***
alpha(1)	8,68136e-05	0,132401	0,0006557	0,9995	
alpha(2)	0,136809	0,0550108	2,487	0,0158	**
alpha(3)	-0,0261580	0,0571752	-0,4575	0,6490	
alpha(4)	-0,0327849	0,0551372	-0,5946	0,5545	

Null hypothesis: no ARCH effect is present

Test statistic: LM = 6,43638

with p-value = $P(\text{Chi-square}(4) > 6,43638) = 0,168844$

SAŽETAK

Nositelji ekonomske politike suočavaju se s brojnim problemima, a neke od glavnih su nezaposlenost, inflacija te plaće. Rast zaposlenih, s jedne strane je vrlo važan parametar, u nekim sferama čak i važniji od nezaposlenosti. To znači da analize o nezaposlenosti treba uzimati i koristiti s rezervom jer je, analizirajući trenutno stanje u Hrvatskoj, pad upravo tog pokazatelja najvećim dijelom uzrokovan odlaskom radno aktivnog stanovništva u inozemstvo. Otkako je Hrvatska počela izlaziti iz gospodarske recesije, plaće su tijekom nekoliko godina realno porasle oko 5%, prema podacima DZS-a. Promatrajući statistiku bruto ili neto plaća u Hrvatskoj, prosječne plaće ne izgledaju (toliko) loše. Međutim, problem je u tome što velika većina zaposlenih u Hrvatskoj prima ispodprosječne plaće, a može se reći čak i minimalne. Posljednjih godina svjedoci smo povećanju cijena hrane i pića, usluga restorana i hotela, duhana, cestarina itd. što ukazuje na pozitivnu stopu inflacije od kraja 2016. godine do danas. Većina ekonomista se slaže da je rast cijena poželjan ako je umjeren te je inflacija redovita popratna pojava svakog gospodarskog napretka. S druge strane, inflacija izazvana povećavanjem poreza možda i nije najpametnija odluka. Dolazi do pitanja rasta (ionako) prevelike sive ekonomije malih i srednjih poduzeća te općenito „gušenja“ poduzetništva, a u Hrvatskoj su pokretači gospodarstva upravo mala i srednja poduzeća kojih ima najveći broj. Cilj ovoga rada je prikazati stanje u Hrvatskoj glede zaposlenosti odnosno nezaposlenosti, stanje bruto i neto plaća, prikazati samu problematiku plaća te analizirati jednu od kompleksnijih pojava unutar svakog gospodarstva a to je inflacija. Svrha rada je analizirati međusoban utjecaj varijabli koje su ekonometrijski i teoretski analizirane u radu. Odabrane varijable prikazuju da svaka pojedinačna varijabla utječe na drugu te ukazuju na veliku povezanost istih. Istraživanje se temelji na procjeni regresijskog modela pomoću ekonometrijskog programa Gretl.

Ključne riječi: inflacija, zaposlenost, nezaposlenost, neto plaće, bruto plaće, bruto domaći proizvod, minimalne plaće, Okunov zakon, Phillipsova krivulja

ABSTRACT

Economic policy makers face many problems, and some of the major are unemployment, inflation and wages. The growth of number of employees is, in a way, a very important parameter, in some spheres even more important than unemployment. This means that unemployment analyzes should be taken and used with reserve, since analyzing the current situation in Croatia, the decline of this indicator is largely due to the departure of a working active population abroad. Since Croatia has started to emerge from the economic recession, wages have risen by about 5% over the years, according to data from National Bureau of Statistics. Looking at gross or net wage statistics in Croatia, average wage do not seems so bad. However, the problem is that the most of the employees in Croatia receive below average and even minimal wages. In recent years, we have witnessed an increase in food and beverage prices, restaurant and hotel services, tobacco, toll, etc., which indicates a positive inflation rate from the end of 2016 to the present. Most economists agree that price growth is desirable if moderate and that economic growth is regularly accompanied by inflation. In another way, inflation caused by rising taxes may not be the smartest decision. It leads to stimulating the (even) excessive growth of gray economy of small and medium-sized enterprises and the general "suffocation" of entrepreneurship, and in Croatia the drivers of the economy are the small and medium sizes enterprises that are also the most numerous. The aim of this paperwork is to present the situation in Croatia with regard to employment or unemployment, the state of gross and net wage, present the wage issue itself and analyze one of the more complex phenomena within each economy, which is inflation. The purpose of the paperwork is to analyze the interaction of variables that are econometrically and theoretically analyzed in the paperwork. The selected variables show that each individual variable affects each other and indicates a high correlation between them. The research is based on the estimating of the regression model using the econometric program Gretl.

Key words: inflation, employment, unemployment, net wages, gross wages, gross domestic product, minimum wages, Okun's law, Phillips curve